

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ENERJİ
VERİMLİLİĞİ KAPSAMINDA ELEKTRİK TÜKETİM
TAHMİNİ: ERZİNCAN İLİNDE BİR UYGULAMA

Ahmet GÖKÇE

Danışman: Doç. Dr. Fulya ASLAY

YAPAY ZEKA VE ROBOTİK
ANABİLİM DALI

ERZİNCAN
2024
Her Hakkı Saklıdır.

Kabul ve Onay Sayfası

Doç. Dr. Fulya ASLAY danışmanlığında, Ahmet GÖKÇE tarafından hazırlanan bu çalışma 22.01.2024 tarihinde aşağıdaki jüri tarafından Yapay Zeka ve Robotik Anabilim Dalı'nda Yüksek Lisans Tezi olarak oybirliği ile kabul edilmiştir.

Başkan: Prof. Dr. Köksal ERENTÜRK İmza:

Üye : Doç. Dr. Fulya ASLAY İmza:

Üye : Doç. Dr. Naim Süleyman TINÇ İmza:

Yukarıdaki sonuç Enstitü Yönetim Kurulunun / / 20.... tarih ve/..... sayılı kararı ile onaylanmıştır.

Doç. Dr. Kemal Volkan ÖZDOKUR
Enstitü Müdür V.

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, şekil ve tabloların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

Bilimsel Etięe Uygunluk Sayfası

“Makine Öğrenmesi Yöntemleri İle Enerji Verimlilięi Kapsamında Elektrik Tüketim Tahmini: Erzincan İlinde Bir Uygulama” isimli “Yüksek Lisans” tezım tarafımca intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiğı gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 22.01.2024

(İmza)

Ahmet GÖKÇE

ÖZET

Yüksek Lisans Tezi

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ENERJİ VERİMLİLİĞİ KAPSAMINDA ELEKTRİK TÜKETİM TAHMİNİ: ERZİNCAN İLİNDE BİR UYGULAMA

Ahmet GÖKÇE

Erzincan Binali Yıldırım Üniversitesi
Fen Bilimleri Enstitüsü
Yapay Zeka ve Robotik Anabilim Dalı

Danışman: Doç. Dr. Fulya ASLAY

Enerji bir ülke için sadece ekonomik değil politik ve çevresel unsurlar için de çok önemlidir. Teknolojik gelişmeler ve refah seviyesinin artmasıyla enerji tüketimi artmıştır. Enerjiye olan ihtiyacın artmasıyla birlikte enerji yönetimi kavramı ortaya çıkmıştır. Önemli enerji kaynaklarından biri de elektrik enerjisidir. Tüm dünyada olduğu gibi ülkemizde de enerji bilinci oluşturulmak için çalışmalar yapılmaktadır. Ülkemizde ortaya konulan enerji politikalarıyla enerjinin verimli kullanılması hedeflenmektedir. Enerji yönetimi sanayi kuruluşları, endüstriyel işletmeler, ticarethaneler ve kamu kurumlarını kapsamaktadır. Kamu kurumları içerisinde okullar önemli bir yer edinmektedir. Gelecekte yapılacak elektrik tüketiminin bilinmesi enerji yönetimi için stratejiler geliştirmeye yardımcı olacaktır. Geleneksel yöntemlerle yapılan tahminlerdeki sınırlamalar ve sorunların üstesinden gelmek için veri madenciliği tekniklerinden faydalanılabilir. Veri madenciliği sayesinde eldeki verilerden anlamlı bilgiye ulaşmak mümkündür. Bu tez çalışmasında makine öğrenmesi yöntemleri kullanılarak Erzincan ilindeki ilköğretim okullarının 2016-2022 yılları arasındaki verileri kullanılarak elektrik tüketimleri tahmin edilmeye çalışılmıştır. Çalışmanın enerji yönetim birimlerine örnek olacağı düşünülmektedir.

2024, 116 Sayfa

Anahtar Kelimeler: Elektrik tüketim tahmini, Enerji verimliliği, Makine öğrenmesi yöntemleri

ABSTRACT

MSc Thesis

ELECTRICITY CONSUMPTION ESTIMATION WITHIN THE SCOPE OF ENERGY EFFICIENCY WITH MACHINE LEARNING METHODS: AN APPLICATION IN ERZINCAN PROVINCE

Ahmet GÖKÇE

Erzincan Binali Yıldırım University
Graduate School of Natural and Applied Sciences
Department of Artificial Intelligence and Robotics

Supervisor: Assoc. Prof. Dr. Fulya ASLAY

Energy is very important for a country not only economically but also politically and environmentally. Energy consumption has increased with technological developments and increasing welfare levels. With the increasing need for energy, the concept of energy management has emerged. One of the important energy sources is electrical energy. As in the whole world, studies are carried out to create energy awareness in our country. It is aimed to use energy efficiently with the energy policies put forward in our country. Energy management includes industrial organizations, industrial enterprises, commercial establishments and public institutions. Schools have an important place among public institutions. Knowing the future electricity consumption will help to develop strategies for energy management. Data mining techniques can be used to overcome the limitations and problems in predictions made by traditional methods. Thanks to data mining, it is possible to obtain meaningful information from the available data. In this thesis, machine learning methods are used to predict the electricity consumption of primary schools in Erzincan province using data from 2016 to 2022. It is thought that the study will be an example for energy management units.

2024, 116 Pages

Keywords: Electricity consumption forecasting, Energy efficiency, Machine learning methods

TEŞEKKÜR

Yüksek lisans eğitimim boyunca her zaman bana yardımcı olan, yol gösteren, bilgi ve birikimini benimle paylaşan değerli danışman hocam Doç. Dr. Fulya ASLAY'A teşekkür ederim.

Bugünlere gelmemi sağlayan, beni yetiştirip büyüten, maneviyatlarını her zaman hissettiğim kıymetli anne ve babama teşekkürü borç bilirim.

Her zaman bana destek olan, yanımda olan kıymetli sevgili eşime, enerji kaynaklarım biricik kızıma ve oğluma teşekkürlerimi sunuyorum.

Ahmet GÖKÇE

Ocak, 2024

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER.....	iv
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ.....	ix
SİMGELER ve KISALTMALAR	x
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ.....	3
3. KURAMSAL TEMELLER.....	20
3.1. Enerji	20
3.2. Enerji Kaynakları ve Türleri	20
3.2.1. Yenilenemez enerji kaynakları.....	21
3.2.2. Yenilenebilir enerji kaynakları.....	21
3.2.3. Birincil enerji kaynakları	22
3.2.4. İkincil enerji kaynakları	22
3.3. Dünya’da Enerji Tüketimi	22
3.4. Türkiye’de Enerji Tüketimi	25
3.5. Türkiye’de Enerji Potansiyeli	26
3.6. Elektrik Enerjisi.....	28
3.7. Elektrik Enerjisi Kullanımının Sektörlere Göre Dağılımı	29
3.8. Türkiye’de Elektrik Üretimi ve Elektrik Kurulu Gücü	30
3.9. Enerji Verimliliği	31
3.10. Enerji Yönetimi.....	32
3.11. Okullarda Enerji Verimliliği ve Yönetimi.....	34
3.12. Okullarda Elektrik Tüketimi.....	35
3.13. Okullarda Elektrik Tüketimini Etkileyen Faktörler	35
3.14. Yapay Zeka	36
3.15. Yapay Zekanın Kullanım Alanları.....	37
3.15.1. Sağlık sektörü	38
3.15.2. Finans ve bankacılık.....	38
3.15.3. Perakende ve e-ticaret	38

3.15.4.	Otomotiv ve ulaşım	39
3.15.5.	Üretim ve endüstri.....	39
3.15.6.	Eğitim ve araştırma	39
3.15.7.	Medya ve eğlence.....	40
3.15.8.	Güvenlik ve gözetim	40
3.16.	Yapay Zeka Kullanılarak Elektrik Tüketiminin Tahmin Edilmesi	41
3.17.	Makine Öğrenimi	42
3.17.1.	Gözetimli öğrenme (denetimli öğrenme)	42
3.17.2.	Gözetimsiz öğrenme (denetimsiz öğrenme)	43
3.17.3.	Pekiştirmeli öğrenme.....	43
3.17.4.	Algoritmalar.....	43
3.18.	Makine Öğrenmesi Algoritmaları	45
3.18.1.	Yapay sinir ağları.....	45
3.18.2.	Yapay sinir ağı modelleri	47
3.18.2.1.	Tek katmanlı yapay sinir ağları.....	48
3.18.2.2.	Çok katmanlı yapay sinir ağları	48
3.18.3.	Çok katmanlı algılayıcı (multi-layer perceptron) yöntemi.....	50
3.18.3.1.	Toplama fonksiyonunun rolü	51
3.18.3.2.	Yaygın aktivasyon fonksiyonları	52
3.18.3.3.	Döngü sayısı (epoch).....	53
3.18.3.4.	Öğrenme katsayısı	53
3.18.3.5.	Momentum katsayısı	54
3.18.4.	Rassal orman yöntemi (random forest regression)	54
3.18.5.	Destek vektör makinesi (support vector machine).....	55
3.18.5.1.	Destek vektör sınıflandırma (support vector classifier)	56
3.18.5.2.	Destek vektör regresyon (support vector regression).....	58
3.18.6.	Doğrusal regresyon (linear regression)	59
3.18.6.1.	En küçük kareler yöntemi	62
3.18.7.	K-en yakın komşu (k-nearest neighbor).....	62
3.18.7.1.	K değerinin belirlenmesi	64
3.18.8.	Lojistik regresyon (logistic regression)	65
3.18.9.	Naive bayes yöntemi	66
3.18.10.	Gaussian naive bayes	67
3.19.	Veri Madenciliği Algoritmalarında Performans Ölçümü	68

3.19.1.	Ortalama mutlak yüzde hata(mean absolute percentage error–MAPE)	68
3.19.2.	Ortalama mutlak hata (mean absolute error - MAE)	69
3.19.3.	Ortalama kare hatası (mean square error - MSE)	69
3.19.4.	Kök ortalama kare hata (root mean square error - RMSE)	69
3.20.	Normalizasyon	70
3.20.1.	Minimum maksimum (min-max) normalizasyon yöntemi	71
3.20.2.	Ondalık ölçekleme normalizasyon yöntemi	71
3.20.3.	Z-Skor normalizasyon yöntemi	72
3.20.5.	Sigmoid normalizasyon yöntemi	73
3.21.	Veri Analizi İçin Programlama Dili Seçimi	73
3.21.1.	Python programlama dili	75
4.	MATERYAL ve YÖNTEM	76
4.1.	Materyal	76
4.1.1.	Makine öğrenmesi yöntemleriyle tahmin yapma	76
4.1.2.	Uygulamada kullanılan yazılımlar	77
4.1.3.	Veri setinin oluşturulması	78
4.1.4.	Veri ön işleme ve temizleme	81
4.1.4.1.	Eksik verileri silme	81
4.1.4.2.	Verilerin normalize edilmesi	81
4.2.	Yöntem	82
4.2.1.	Rassal orman yöntemi ile elektrik tüketimini tahmin etme	83
4.2.2.	Destek vektör makinesi yöntemi ile elektrik tüketimini tahmin etme	85
4.2.3.	K-en yakın komşu yöntemi ile elektrik tüketimini tahmin etme	87
4.2.4.	Doğrusal regresyon yöntemi ile elektrik tüketimini tahmin etme	89
4.2.5.	Çok katmanlı algılayıcı yöntemi ile elektrik tüketimini tahmin etme	90
5.	BULGULAR	95
6.	SONUÇ	97
	KAYNAKLAR	99

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1. Enerji Kaynaklarının Sınıflandırılması	21
Şekil 3.2. Fosil Yakıt Rezervleri ve Gelecek Tahminleri	23
Şekil 3.3. 2021 Yılı Dünya’da Yenilebilir Enerjiye Dayalı Kurulu Güç Dağılımı	23
Şekil 3.4. Bazı Ülkeler İçin Kişi Başına Düşen Enerji Tüketimi	24
Şekil 3.5. 2019 Yılı Dünya’da Enerji Kaynakları Dağılımı	25
Şekil 3.6. Ülkemizde Yıllara ve Sektörlere Göre Enerji Tüketimi	26
Şekil 3.7. Ülkemizdeki Yenilenebilir Enerji Kaynaklarının Kendi İçindeki Dağılımı...	27
Şekil 3.8. Dünya Elektrik Tüketimi Sektörel Dağılımı.....	29
Şekil 3.9. Ülkemizde Yıllara ve Sektörlere Göre Elektrik Enerjisi Tüketimi	30
Şekil 3.10. 2020-2035 Yılı Kaynaklara Göre Kurulu Güç Hedefleri	
Şekil 3.11. Biyolojik Sinir Hücresi	45
Şekil 3.12. Basit Yapay Sinir Ağı Yapısı.....	46
Şekil 3.13. Tek Katmanlı Yapay Sinir Ağı Modeli	48
Şekil 3.14. Çok Katmanlı Yapay Sinir Ağı Modeli.....	49
Şekil 3.15. Çok Katmanlı Algılayıcı Yapısı.....	51
Şekil 3.16. Destek Vektör Makinesi Genel Yapısı	56
Şekil 3.17. 2 Sınıflı Doğrusal Ayrılabilen Problem Örneği	57
Şekil 3.18. 2 Sınıflı Doğrusal Ayrılmayan Problem Örneği	57
Şekil 3.19. Doğrusal (solda) ve Doğrusal Olmayan (sağda) SVR Örneği.....	59
Şekil 3.20. Doğrusal Regresyon Grafiği	60
Şekil 3.21. K En Yakın Komşular Algoritması İçin İki Sınıflı Örnek.....	63
Şekil 3.22. Sigmoid Fonksiyonu Grafiği	66
Şekil 4.1. Jupyter Notebook Ara Yüzü	77
Şekil 4.2. Okulların Elektrik Tüketimleri	79
Şekil 4.3. 2016-2022 Yılları Arasında Okullardaki Elektrik Tüketimi Değişimi	80
Şekil 4.4. 106 Okulun 2016-2022 Yılları Arasındaki Toplam Elektrik Tüketimleri.....	80
Şekil 4.5. Temel Makine Öğrenmesi Süreci	83
Şekil 4.6. Rassal Orman Yöntemi ile Tahminleme	84
Şekil 4.7. Örnek Düğüm Yapısı.....	84
Şekil 4.8. Destek Vektör Makinesi Yöntemi ile Tahminleme	85

Şekil 4.9. Kapalı Alan ve Elektrik Tüketimi Arasındaki İlişki	86
Şekil 4.10. Kişi Sayısı ve Elektrik Tüketimi Arasındaki İlişki	86
Şekil 4.11. Sınıf Sayısı ve Elektrik Tüketimi Arasındaki İlişki	87
Şekil 4.12. K-En Yakın Komşu Yöntemi ile Tahminleme	88
Şekil 4.13. Gerçek ve Tahmin Edilen Değerlerin Regresyon Çizgisi	88
Şekil 4.14. Doğrusal Regresyon Yöntemi ile Tahminleme.....	89
Şekil 4.15. Hata Dağılımı Grafiği.....	90
Şekil 4.16. Eğitim Kaybı Grafiği.....	91
Şekil 4.17. Çok Katmanlı Algılayıcı Yöntemi ile Tahminleme	93
Şekil 4.18. Ağırlık Grafiği.....	94
Şekil 4.19. Bias Grafiği.....	94
Şekil 5.1. Modellerin MAPE Değerleri	96

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Biyolojik ve Yapay Sinir Ağının	47
Tablo 4.1. Katman ve Katmanlardaki Nöron Sayılarına Göre MAPE Değerleri	92
Tablo 4.2. Katmanlardaki Transfer Fonksiyonlarına Göre MAPE Değerleri	93
Tablo 5.1. Model Performanslarının Değerlendirilmesi	96



SİMGELER ve KISALTMALAR

Simgeler

α	Güvenirlilik Katsayısı
β	Beta Katsayısı
e	Doğal Logaritmik Değer
ε	Epsilon
μ	Ortalama Değer
σ	Standart Sapma
φ	Fi Sayısı
Σ	Toplam Sembolü
%	Yüzde

Kısaltmalar

AUC	Area Under The Curve
ANFİS	Adaptive Neural Fuzzy Inference System
BP	British Petroleum
CSB	Çevre Şehircilik Bakanlığı
DVM	Destek Vektör Makinesi
ETKB	Enerji Tabii ve Kaynaklar Bakanlığı
GSYİİ	Gayri Safi Yurt İçi Hasıla
GW	Gigawatt
IEA	International Energy Agency
J	Joule
JKBB	Enerji Kentleri Birliği
KNN	K Nearest Neighbor
KWH	kilowatt saat
LPG	Likit Petrol Gazı

LSTM	Long Short-Term Memory
M	Metre
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MLP	Multi Layer Perceptron
MSE	Mean Square Error
MW	Megawatt
OECD	Ekonomik Kalkınma ve İşbirliği Örgütü
RMSE	Root Mean Square Error
ROC	Receiver Operating Characteristic
SVC	Support Vector Classifier
SVM	Support Vector Machine
SVR	Support Vector Regression
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TEP	Ton Eşdeğer Petrol
TWH	Terawatt Saat
UEA	Ulusal Enerji Ajansı
YSA	Yapay Sinir Ağı

1. GİRİŞ

Enerji, insan yaşamındaki olmazsa olmaz unsurlardan biridir. Ülkemizdeki refah seviyesinin artması ve teknolojik gelişmelerle birlikte enerji tüketimi de artış göstermektedir. Ülkemizin ekonomisi üzerindeki en büyük yüklerden biri de enerji giderleridir(Odası, M.M.,2008). Enerji tüketiminin ve enerjiye olan ihtiyacın artmasıyla birlikte enerji yönetimi, enerji tasarrufu ve enerji verimliliği gibi kavramlar daha çok gündeme gelir olmaktadır. Enerji yönetimi enerjinin optimum derecede kullanılması iken enerji verimliliği ise konfordan ödün vermeden enerjinin etkin şekilde kullanılmasıdır. Şirketler enerjiden tasarruf etmek amacıyla bünyelerinde enerji yöneticisi bulundurmaya başlamışlardır(Özbakır, 2006). Enerji yönetimi sadece endüstriyel işletmeleri ve ticarethaneleri değil kamu kurumlarını da kapsamaktadır. Enerji kaynaklarının öneminin belirgin bir şekilde arttığı günümüzde kanun, yönetmelik ve genelgelerle enerjinin verimli kullanılması hedeflenmektedir. 5627 sayılı Enerji Verimliliği Kanunu kapsamında yıllık toplam enerji tüketimi 250 TEP ve üzeri veya toplam kapalı alanı 10.000 m² ve üzeri kamu binalarında 2019/18 sayılı Cumhurbaşkanı Genelgesi uyarınca 2023 yılının sonunda %15 enerji tasarrufu sağlanmalıdır. Bu hedef 04/11/2023 tarih ve 2023/15 sayılı Cumhurbaşkanı Genelgesi ile 2030 yılı sonuna kadar asgari %30 enerji tasarrufu yapılması olarak güncellenmiştir. Enerji tasarrufu sağlanırken referans tüketimi dikkate alınmalıdır. Referans tüketimi ise 2016-2018 yılları arasında yapılan tüketimlerin aritmetik ortalamasıyla elde edilir. Bir il bünyesinde çeşitli kamu kurumları yer almakla birlikte tüm okulları tek bir kamu kurumu gibi düşündüğümüzde enerji tüketiminin en fazla olduğu kamu kurumları içerisinde okullar yer almaktadır. Bu nedenle okullarda alınacak enerji tüketim tedbirleri çok daha fazla önem arz etmektedir. Ayrıca okullarda oluşturulacak tüketim bilinci öğrencilere yansıdığına bu bilinç ülkemize de yansımış olacaktır. Geçmiş yıllarda yapılan enerji tüketimlerinden yola çıkılarak gelecekte gerçekleşecek enerji tüketimi makine öğrenmesi gibi yapay zeka temelli çeşitli yöntemlerle tahmin edilebilir. Böylece hedeflenen enerji tasarrufu ile tahmin edilen enerji tüketimi karşılaştırılarak bir yol haritası çizilebilir. Enerji tüketim tahminlerinin yüksek çıkması halinde yeni tedbirler gündeme alınarak uygulamaya koyulabilir.

Yapılan araştırmalar gösteriyor ki önümüzdeki yıllarda dünya genelinde enerji kaynağı tedarikinde sıkıntılar yaşanabilir (Özalp, 2019). Yaşanabilecek enerji krizlerini göz

önünde bulunduran ülkeler enerji tüketim tedbirlerini alıp hayata geçirmekte ve enerji politikalarına ağırlık vermektedir. Ülkemizde de geliştirilen politikalarla enerji yoğunluğunun 2023 yılı sonuna kadar %20 düşürülmesi hedeflenmektedir. Ülkemizde Enerji Verimliliği kanunu 2007 yılında çıkarılmıştır. Daha sonraki yıllarda bu kanuna dayanan çeşitli yönetmelik ve kararnamelere enerji verimliliği alanında tedbirler alınmaya devam edilmiştir. Milli Eğitim Müdürlükleri bünyesinde 5627 sayılı enerji verimliliği kanunu gereği kurulan enerji yönetim birimlerince çeşitli tasarruf tedbirleri alınarak tüketimin düşürülmesi hedeflenir. Bu doğrultuda 2023 ve 2030 hedeflerine ulaşmaya çalışılır. Bu çalışma sonucu elde edilecek tüketim tahminiyle enerji piyasasında daha sağlıklı bir planlama yapılması amaçlanmaktadır.

Günümüzde verilerin depolanması ve depolanan verilere ulaşmak daha kolay bir hale gelmiştir. Ancak her verinin depolanması ile veri miktarının artması bu veri yığınlarından anlamlı sonuçlar çıkarmayı zor bir hale getirmiştir. Veri madenciliği sayesinde elde bulunan veriden anlamlı ve işe yarar bilgiler çıkarmak mümkündür (Yurtsever, 2002). Teknolojinin bu kadar ilerlediği günümüzde veri madenciliğinin kullanım alanları çok yaygınlaşmıştır. Literatürde enerji verimliliği ve yönetimi alanlarında da veri madenciliği ile yapay zeka yöntemlerini kullanan birçok makale bulunmaktadır.

Bu çalışma ile yapay zeka yöntemlerinden makine öğrenmesi algoritmaları kullanılarak enerji tüketim tahmini gerçekleştirilmiştir. Bunun için Erzincan ili bünyesindeki Milli Eğitime bağlı 106 ilköğretim okuluna ait 2016-2022 yılları arasındaki elektrik tüketim verileri gerekli etik onayı alınarak elde edilmiştir. Veri seti enerji tüketim değerleri ile birlikte derslik sayısı, kapalı alan metrekaresi ve öğrenci sayısı gibi parametrelerden oluşmaktadır. Bu verilerden yola çıkılarak makine öğrenmesi algoritmaları ile 2016-2021 yılları arasındaki veriler eğitim seti olarak ayrılarak 2022 yılı elektrik tüketimi tahmini tahmin edilmiştir ve gerçek tüketim değerleriyle karşılaştırılmıştır. Bu çalışma ile elde edilen sonuçların Milli Eğitim Müdürlükleri bünyesinde kurulan Enerji Yönetim Birimlerine de yol gösterici olması beklenmektedir.

2. KAYNAK ÖZETLERİ

Golovinski vd. (2002) kullanıcıların davranışlarına göre binalardaki elektrik tüketimini tahmin etmeye yarayan bir simülasyon çerçevesi hazırlamışlardır. Enerji verimliliği açısından tüketimin azaltılması gerekirken kişilerin konforlarından ödün verilmemesi gerektiği belirtilmiştir. Elektrik tüketiminin doğru tahmin edilmesi ile enerji verimliliği kapsamında yapılacak planlamaların daha verimli olacağı ifade edilmiştir. Çalışma için gerekli veriler üniversite kampüsünde yer alan öğrencilere uygulanan anketle elde edilmiştir. LSTM tabanlı regresyon tekniğiyle bir öğrencinin günlük elektrik tüketim modeli çıkarılmıştır.

Yalçınöz vd. (2002) çalışmalarında yapılacak yatırımların belirlenebilmesi için geleceğe yönelik elektrik yük tahmininde bulunulması gerektiğini belirtmişlerdir. Niğde ili için 1991-2001 yılları arasındaki elektrik tüketim verileriyle çok katmanlı yapay sinir ağları kullanılarak 2001-2004 yılları için gerekli elektrik ihtiyacı tahmin edilmeye çalışılmıştır. 2001 yılı için tahmin değerleri ve gerçek değerler karşılaştırılmış ve birbirine çok yakın olan sonuçlar elde edilmiştir.

Yusuf ve Soner (2003) yapmış oldukları çalışmada elektrik tüketimin yapıldığı ev, sanayi, işyeri gibi ortamlarda elektrik talebine nelerin etki ettiğini ortaya koymaya çalışmışlardır. Bu etkenlerin bilinmesi halinde daha kararlı elektrik üretimi yapılabileceğini söylemişlerdir. Konutlardaki elektrik talebinde hane gelirinin önemli bir etken olduğunu ortaya koymuşlardır.

Ceylan (2004) yapmış olduğu yüksek lisans tez çalışmasında enerji üretiminde ve yönetiminde atılması gereken en adımlardan birinin kısa dönem yük ihtiyacının belirlenmesi olduğunu belirtmiştir. Bunun için çalışmada Gölbaşı bölgesinde elektrik tüketim verilerini kullanıp bir sonraki gün için gerekli olan elektrik enerjisini tahmin etmeye çalışmıştır. Yapay sinir ağı yöntemi ve regresyon analizi kullanılarak yapılan çalışmada en iyi tahminin yapay sinir ağıyla bulunduğunu gözlemlemiştir. Elektrik tüketime etki eden faktörler olarak gün içindeki minimum ve maksimum sıcaklık değerlerini çalışmada kullanmıştır.

Hamzaçebi ve Kutay (2004) çalışmalarında temiz enerji kaynağı olan elektrik enerjisinin depolanamadığı için ihtiyacın doğru tahmin edilebilmesinin çok önemli olduğunu ifade etmişlerdir. Ülkemizdeki uzun dönem elektrik ihtiyacı tahmini için yapay sinir ağı tekniklerini kullanmışlardır. Yapay sinir ağı teknikleri ile elde ettikleri sonuçları regresyon tekniği ve box-jenkins metotları ile test etmişlerdir. Sonuç olarak yapay sinir ağı teknikleri ile uzun dönem elektrik ihtiyacı tahmininde daha başarılı sonuçlar elde edildiğini söylemişlerdir.

Akkurt (2005) yüksek lisans tez çalışmasında elektrik enerjisi için planlamanın çok önemli olduğundan bahsetmiştir. Çünkü elektrik enerjisinin yatırım maliyeti yüksektir ve bu yatırımın dönüşüm süreside uzundur. Yaşamın ve gelişim sürekliliği için elektrik enerjisinin kesintisiz temini şarttır. Farklı ülkelerde yapılan elektrik enerjisi ihtiyacı talep çalışmalarına yer verilmiş ve ülkemizde yapılan çalışmalardan bahsedilmiştir. Çalışmada yapay sinir ağları kullanılarak ülkemiz için elektrik ihtiyacı tahmin edilmeye çalışılmıştır.

Mohamed ve Bodger (2005) Yeni Zelanda için GSYİH, nüfus ve elektrik birim fiyatını kullanarak çoklu doğrusal regresyon modeliyle elektrik tüketim tahmininde bulunmaya çalışmışlardır. Tahminler ulusal tahminlerle ve istatistiksel testlerle karşılaştırılmış ve başarı elde edilmiştir.

Muhsin ve Kınık (2008) çalışmalarında enerji kaynakları arasında elektrik enerjisini ayrı bir yere koymuşlardır. Ülkemizdeki ekonomik büyüme ile elektrik enerjisi tüketimi arasındaki ilişkiyi incelemeye çalışmışlardır. Bunun içinde ekonometrik yöntemleri kullanmışlardır. Elektrik tüketimini mesken, sanayi ve toplam olmak üzere üç başlık altında ele almışlardır. Sonuç olarak mesken elektrik tüketimi ile hane kişi başı gelir arasında uzun dönemli bir ilişki olduğunu ve toplam elektrik tüketimiyle ekonomik büyümenin de orantılı olduğunu tespit etmişlerdir.

Bilgili (2009) çalışmasında LR, NLR ve YSA yöntemlerini kullanarak ülkemiz için net elektrik tüketim tahmininde bulunmaya çalışmıştır. Abone sayısı, nüfus, kurulu güç ve brüt elektrik üretimi bağımsız değişkenler olarak kullanılmıştır. Elde edilen sonuçlar Enerji ve Tabii Kaynaklar Bakanlığı literatüründeki verilerle karşılaştırılmıştır. İki senaryo elde edilmiştir. Olabilecek en fazla ve düşük tüketim ihtiyaçları belirlenmiştir.

Sonuç olarak yapay sinir ağılarıyla yapılan tahminin daha iyi sonuçlar verdiği görülmüştür.

Nişancı (2005) çalışmasında ülkemizdeki farklı sektörlerin elektrik tüketimlerini tahmin etmeye çalışmış ve elektrik tüketimiyle milli gelir arasındaki nedensellik ilişkisini ortaya koymaya çalışmıştır. Zamanın ilerlemesiyle kişi başı elektrik tüketiminin nüfusa ve gelire göre daha fazla artış gösterdiğini belirtmiştir. 1970-2003 yılları arasındaki kişi başı elektrik tüketimi ile kişi başı gelir verilerini incelediğinde elektrik tüketimi artışının gelir artışından daha fazla olduğunu ortaya koymuştur.

Karagöl vd. (2007) çalışmalarında elektrik tüketimini farklı bir açıdan incelemişlerdir. Elektrik tüketimi ile ülkemizdeki ekonomik büyüme arasındaki ilişkiyi tespit etmeye çalışmışlardır. 1974-2004 arası elektrik tüketim verileri ile ekonomik verileri kullanarak yaptıkları çalışmalarında kısa süreli değerlendirmede elektrik tüketimi ile ekonomik büyümenin doğru orantılı olduğunu ancak uzun süreli değerlendirmede ise elektrik tüketimi ile ekonomik büyüme arasında ters orantı olduğunu görmüşlerdir.

Azadeh vd. (2008) yüksek enerji tüketen endüstriyel sektörlerin yıllık elektrik tüketimini tahmin edebilen bir model geliştirmeye çalışmışlardır. Geleneksel regresyon modelleriyle yüksek elektrik tüketimlerinin olduğu endüstriyel işletmelerde elektrik tüketimi tahmini yapılmasının hatalı sonuçlanabileceğini belirtmişlerdir. Bu sebeple yapay sinir ağı kullanarak sonuca ulaşmaya çalışmışlardır. Çalışma da İran'da 1979-2003 yılları arası yüksek elektrik tüketen endüstrilerden alınan gerçek veriler kullanılmıştır.

Bianco vd. (2009) İtalya'da 1970-2007 yılları arasındaki elektrik tüketim, nüfus ve GSYİH verilerini kullanarak çoklu regresyon tekniğiyle 2030'a kadar olan uzun dönem elektrik tüketim tahmininde bulunmaya çalışmışlardır. Sonuç olarak geliştirilen regresyonların en iyi durum için ± 0.1 ve en kötü durum için ± 0.11 'lik sapmalarla resmi tahminlerle uyumlu olduğunu görülmüştür.

Demirel vd. (2010) çalışmalarında çağdaş bir hayat için en önemli unsurlardan biri olan elektrik enerjisinin önemine vurgu yapmışlardır. Ülkemizde her geçen yıl bir önceki yıla göre daha fazla elektrik tüketimi olduğunu belirtmişlerdir. Darboğazların olmaması, talebe göre yeterli arzın sağlanabilmesi ve sistemin bakımı için geleceğe yönelik elektrik

talebini tahmin ederken ülkemizdeki 1970-2007 yılları arası GSMH, üretilen ve tüketin elektrik, nüfus ve kurulu güç gibi verileri kullanmışlardır. Talep tahmini için ARPA ve ANFİS modellerinden faydalanmışlardır. 2006-2010 yılları için elektrik talebini ANFİS modelleriyle çok daha verimli bir şekilde tahmin etmişlerdir.

Kaya (2010) yüksek lisans tez çalışmasında tek bir kuruma ait elektrik tüketim tahmininde bulunmaya çalışmıştır. Sektördeki büyük şirketler için en büyük giderlerden biri olan elektrik tüketiminin tahmin edilmesinin şirketin mali analizi için önemli olduğuna dikkat çekmiştir. Ülkemiz için önemli kurumlardan biri olan Türk Telekom A.Ş.'nin yoğun müşterisinin bulunduğu İstanbul Anadolu yakasındaki 120 aylık tüketim verileri kullanılarak yapay sinir ağlarıyla elektrik tüketim tahmininde bulunulmaya çalışılmıştır. Değişkenler olarak sıcaklık verileriyle adsl abone sayıları kullanılmıştır. Bir telekomünikasyon şirketi olan Türk Telekom A.Ş. de enerji, 7 gün 24 saat kesintisiz hizmet verilebilmesi için kritik önem arz etmektedir. Çalışma sonucu hata oranları karşılaştırılmış ve en iyi sonucun MLP modeliyle alınabildiği kanaatine varılmıştır

Toker ve Korkmaz (2010) çalışmalarında talep tarafının ileriye yönelik elektrik tüketim tahminini gün öncesi planlama sistemine verdiğini belirtmiştir. Gün öncesi planlama sistemi kendisine verilen tahmin doğrultusunda gün öncesinden sistemin dengesini ayarlamaktadır. Verilen tahminlerin doğruluk payının düşük olması durumunda gerçek zamanda sistem dengesiz olarak çalışmaktadır. Bunun önüne geçebilmek için saatlik ihtiyaç tahmininde bulunulması gerekmektedir. Bu doğrultuda sıcaklık, ısıma, takvim verileri ve elektrik tüketimi gibi veriler kullanılarak yapay sinir ağları ve ileri sinyal işleme teknikleriyle ülkemizdeki elektrik talebinin saatlik olarak günlük ve haftalık tahminleri yapılmıştır.

Yılmaz (2010) yapmış olduğu yüksek lisans tez çalışmasında ülkemizdeki ve dünyadaki elektrik talebini incelemiş ve Tokat ilindeki enerji ihtiyacını tahmin etmeye çalışmıştır. 2010-2015 yılları için kişi başına düşen elektrik ihtiyacını tahmin etmeye çalışmış ve Tokat ile çevre illerin tüketimlerini mukayese etmiştir. Tahminde bulurken elektrik tüketimleriyle birlikte nüfus, gelir ve elektrik fiyatı gibi değişkenleri kullanmıştır.

Yıldırım (2010) yapmış olduğu yüksek lisans tez çalışmasında Malatya ilindeki okulların su, doğalgaz ve elektrik tüketimleri ile okulların fiziki yapıları ve öğrenci sayıları gibi

faktörler arasındaki ilişkiyi ortaya koymaya çalışmıştır. Benzer okullar arasındaki tüketim farklılıklarının nedenlerini bulmaya çalışmıştır. Çalışmasıyla okullarda enerji tüketiminde bilinç oluşturmaya hedeflemiştir. Çalışmasında il genelindeki ilköğretim okullarının yaklaşık olarak 18 aylık tüketim faturalarını, okul derslik sayılarını, öğrenci sayılarını kullanarak regresyon analiz yapmıştır. Çalışmasıyla okullarda yer alan çeşitli verilerden anlamlı bilgiler çıkarıp kişi başına düşen tüketimleri bulmuş ve fazla tüketime sebep olan etmenleri ortaya koymuştur.

Özdemir (2011) yüksek lisans tez çalışmasında elektrik enerjisine olan bağımlılığımızdan bahsedip, tüketicilere kesintisiz ve kaliteli elektrik enerjisi sağlamanın gerekliliğinden bahsetmiştir. Geleceğe yönelik elektrik enerjisi tahmini yaparken sıcaklık ve nüfus gibi etkenleri göz önünde bulundurmuştur. Kocaeli iline ait 2002-2010 yılları arasındaki elektrik tüketim verileriyle yapay sinir ağı tekniği kullanılarak geleceği yönelik tüketim tahmininde bulunmaya çalışmıştır.

Kaytez (2012) yapmış olduğu doktora tez çalışmasında gelecekteki elektrik tüketiminin doğru tahmin edilmesinin devletlere birçok alanda karar almada büyük katkı sağlayacağını belirtmiştir. Elektrik ihtiyacının her geçen gün arttığını ve üretiminde bu artışın tahmin edilerek yapılması gerektiğini söylemiştir. Çalışmasında ülkemizdeki 2018 yılına kadar olacak net elektrik tüketimini bulmaya çalışmıştır. Elektrik tüketim tahmini için nüfus, abone sayısı, brüt elektrik üretimi ve kurulu güç değişkenlerini kullanmıştır. Çalışmasında ÇLR, YSA ve EKK-DVM metotlarını kullanmış ve en iyi sonucu en küçük kareler destek vektör makineleri tekniğiyle elde etmiştir.

Marvuglia ve Messineo (2012) gelişmiş ülkelerde konutlarda özellikle klima kullanımından ötürü elektrik tüketiminin arttığına dikkat çekmişlerdir. Bu nedenle bu çalışmada elektrikli ev aletlerinin türü ile elektrik tüketimi arasındaki ilişkiyi değerlendirmek için Palermo'daki bir bölge için yapay sinir ağı kullanılarak kısa süreli elektrik tüketim tahmini yapılmıştır.

Tütün (2012) yapmış olduğu yüksek lisans tez çalışmasında gelecekte ihtiyaç duyulan elektrik enerjisinin doğru planlanmaması durumunda yüksek maliyetli sonuçların doğabileceğini söylemiştir. Çalışmasında ülkemizdeki uzun dönem elektrik ihtiyacını bulmaya çalışmıştır. Çalışması için 1976-2010 yılları arasındaki elektrik tüketim

verilerini kullanmıştır. Fazla değişken kullanımının olumsuz sonuçlar vermesi nedeniyle ithalat, ihracat, üretim ve kullanılan enerji değişkenlerini çalışmada kullanmıştır. Farklı yöntemler deneyerek yapmış olduğu tahmin çalışmasında en iyi sonucun ANFIS (Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi) tekniğiyle bulunduğu sonucuna varmıştır.

Atalay (2013) yüksek lisans tez çalışmasında elektrik enerjisinin ihtiyaca göre anlık üretilmesi gerektiğini söylemiştir. Üretimde aksamaların olmaması için geleceğe yönelik doğru ihtiyaç tahmininde bulunulması gerektiğini ifade etmiştir. Ekonomik, zamansal, meteorolojik ve rastlantısal etmenlerin elektrik tüketimine etki ettiğini belirtmiştir. Çalışmada makine öğrenme yöntemlerinden yapay sinir ağlarını ve destek vektör makineleri tekniğini üst sezgisel yöntemlerle artırarak kullanmıştır. 5000 ticari işletme ile Doğu Slovyakya'nın tamamına ait elektrik tüketimi verilerini içeren iki veri setiyle yapılan çalışmadan en verimli sonuçlara destek vektör makineleri tekniğiyle ulaşmıştır.

Boltürk (2013) yüksek lisans tez çalışmasında ülkemizde elektriğin önceden devlet kontrolünde iken günümüzde ise özel şirketlerin kontrolünde olduğunu belirtmiştir. Elektrik dağıtım şirketleri tüketicilere lazım olacak elektriği önceden tahmin etmelidirler. Süreçte talebin önceden tahmin edilmesi arzın tedariki için önemlidir. Elektrik dağıtım şirketleri kullanıcıların elektrik talebini tahmin edebilmek için değişik yöntemler kullanırlar. Düz varsayımlarla yapılan tahminler, sektör uzmanlarından alınan görüşler ve matematiksel yöntemlerle geçmiş veriler üzerinde yapılan işlemlerle yapılan tahminleme yolları bulunmaktadır. Bu çalışmada bir dağıtıcı firmanın 2000-2012 yılları arasındaki verileri kullanılarak kısa, orta ve uzun dönemli elektrik ihtiyacı tahminleri çeşitli makine öğrenmesi yöntemleriyle bulunmaya çalışılmış ve en etkili yöntem ortaya çıkarılmak istenmiştir. Kısa, orta ve uzun dönem tahminleri için bulanık mantık yöntemlerinin etkili sonuçlar verdiği görülmüştür.

Yavuzdemir ve Gökğöz (2014) çalışmalarında birincil enerji kaynaklarına yer vermiş ve elektriğin birincil enerji kaynaklarından elde edilen ikinci enerji kaynağı olduğunu belirtmişlerdir. Ülkemizdeki kurulu gücün 1913 yılından 2013 yılına kadar ki değişimine yer verilmiştir. Kurulu elektrik gücümüzün hangi kaynaklardan ne oranda elde edildiğine yer verilmiştir. Dünyadaki nihai elektrik tüketimi her geçen yıl artmaktadır. Gelişmiş ülkelerde elektrik tüketimiyle ekonomik büyüme arasında doğru orantı vardır. Gelişmekte olan ülkelerde ise kişi başına düşen gelir elektrikli araçların kullanımının artmasıyla

birlikte artmaktadır. Ülkemizde kişi başına elektrik tüketimi dünya ortalamasının biraz üzerindeyken OECD ülkelerine göre ortalamanın baya altındadır. Elektrik talebinin altında veya üstünde enerji arzının sağlanması ortaya sorunlar çıkarır. Bu sebeple elektrik enerjisi ihtiyacı hassas şekilde ortaya konulmalıdır. Çalışmada ülkemizde kısa dönemli yıllık elektrik brüt ihtiyacı regresyon, bulanık mantık ve zaman serisi teknikleriyle ayrı ayrı bulunmaya çalışılmıştır. 2018 yılı için elektrik ihtiyacı zaman serisi modeliyle daha iyi performansla bulunmuştur.

Bicil (2015) yapmış olduğu doktora tez çalışmasında dünyadaki tüm endüstrilere paralel olarak elektrik piyasalarının da serbestleştğini belirtmiştir. Ülkemizde de bu durum bir kanun çıkarılarak sonuçlanmıştır. Elektrik fiyatları önemli ekonomik değişkenlerden biridir. Elektrik fiyatlarının kullanıcılara göre şekillendiği bir piyasa hâkimdir. Elektrik fiyatlarının belirlenmesini açıklayan bir sistemin oluşturulması herkes için önemlidir. Çalışmada elektrik fiyatını tahmin etmek için kullanılan modellerden ve veri setlerinden kaynaklı farklı sonuçların ortaya çıktığı hipotezi savunulmuştur. Bu çalışmada elektrik fiyatlarını tahmin eden farklı metotların başarımları incelenmiştir. 2013-2014 yılları arasında fiyat öngörü oynaklığın düşük olduğu dönemlerde ARMA modelinin ve oynaklığın yüksek olduğu dönemlerde ise çok katmanlı algılayıcının performansının yüksek olduğu belirlenmiştir.

Ergün ve Polat (2015) çalışmalarında OECD ülkelerinin elektrik tüketimlerini, büyümelerini ve CO₂ emisyonlarını inceleyerek aralarında nasıl bir ilişki olduğunu ortaya koymaya çalışmışlardır. Elektrik tüketimleri ile CO₂ emisyonları arasında doğrusal bir ilişki olduğu, CO₂ emisyonuyla büyüme arasında ise doğrusal bir ilişki olmadığını ortaya koymuşlardır. Çalışmalarında 1980-2010 yılları arasındaki verilerin logaritmik değerleri panel veri yöntemi ile analiz etmişlerdir.

Hussain vd. (2016) Pakistan'da artan elektrik kesintilerinin sektörlerin ekonomilerini olumsuz etkilediğini belirtmişlerdir. Tüketim-üretim açığının önüne geçebilmek ve doğru strateji geliştirebilmek için elektrik tüketim tahmini yapmanın şart olduğu ifade edilmiştir. Arz-talep açığını kapatabilmek için 1980-2011 arasındaki zaman serisi verileri kullanılarak Holt-Winter ve ARIMA modelleriyle tüketim tahmininde bulunulmuştur. Holt-Winter modeliyle daha sağlam sonuçlar alınmıştır.

Makas ve Karaatlı (2016) çalışmalarında üretilen elektrik enerjisinin depolanamadığından arz talep dengesinin planlanması açısından ne kadar elektrik enerjisine ihtiyaç olduğunun bilinmesi gerektiğini belirtmişlerdir. Bunun için bir hidroelektrik santralinin gelecekteki elektrik üretim miktarını tahmin etmeye çalışmışlardır. Yapay sinir ağıyla 2007-2014 yılları arasındaki verileri kullanıp 2015 yılı için üretilecek elektrik miktarını tahmin etmişlerdir. Yenice deresi üzerindeki bir hidroelektrik santralinin aylık üretim miktarını başarılı bir şekilde tespit etmişlerdir.

Karaca ve Karacan (2016) çalışmalarında ülkemizdeki gayri safi yurt içi hasıla ile elektrik tüketim miktarı arasında doğru orantı olduğunu göstermişlerdir. Elektriği depolamanın zorluğundan bahsederek ihtiyaç doğrultusunda elektrik arz edilerek kullanılması gerektiğini belirtmişlerdir. 2003-2009 yılları arasındaki dünya bankası verilerini kullanarak kişi başı elektrik tüketimini tahmin etmeye çalışmışlardır.

Kaynar vd. (2016) ekonomik büyümenin devam etmesi için enerjinin önemli olduğuna dikkat çekip, nüfus artışıyla birlikte enerjiye olan ihtiyacında arttığını belirtmişlerdir. Destek vektör regresyon yöntemiyle ülkemizdeki 1974-2014 yılları arasındaki elektrik tüketim verilerini, nüfus, ithalat ve ihracat verilerini kullanarak modelleme yapmışlardır. %3.66 hatayla ülkemizdeki yıllık elektrik tüketimini modellemişlerdir.

Masaebi (2016) yüksek lisans tez çalışmasında İran'da geleceğe yönelik elektrik tüketim tahmininde bulunmaya çalışmıştır. Gelişen teknoloji ve sanayiyle elektrik enerjisi tüketiminin artışa geçtiğine dikkat çekip, elektrik üretim, dağıtım ve iletimiyle ilgili doğru planlamalar yapılması gerektiğini belirtmiştir. Bunun içinde doğru tüketim tahmini yapılmasının önemine vurgu yapmıştır. Çalışmasında 1974-2014 yılları arasındaki verileri kullanarak nicel tahmin yöntemlerinden yapay sinir ağlarını kullanarak tahminde bulunmuştur. Doğruluğu test etmek içinde çoklu regresyon modelleri kullanmıştır. Veri tabanında ithalat, ihracat, nüfus, GSYİH, elektrik satış fiyatı, büyüme oranı ve elektrik tüketim verileri kullanılmıştır. Çalışma sonunda tahmini değerlerle gerçek değerler arasında çok yakınlık olduğu görülmüştür.

Başoğlu ve Bulut (2017) çalışmalarında her ülkedeki elektrik ihtiyacını tahmin edebilecek genel bir sistemin olmadığından bahsetmişlerdir. Ülkelerin en önemli hedeflerinden biri kullanıcılarına kesintisiz ve güvenli elektrik enerjisi sağlamaktır. Elektrik arzının sağlıklı

bir şekilde sağlanabilmesi için elektrik ihtiyacının önceden bilinmesi gerekmektedir. Her ülkenin elektrik ihtiyacını tahmin edebilmek için kullanılan sistemler şartlara göre değişiklik göstermektedir. Ülkemizdeki kısa dönem elektrik ihtiyacını tahmin edebilmek için yapay sinir ağları ve uzman sistemleri içeren hibrit bir sistem geliştirilmiştir. Böylece tahminlerdeki hatalar minimize edilmeye çalışılmıştır.

Kocadayı vd. (2017) çalışmalarında Zonguldak, Karabük ve Bartın illerini içerisine alan TR81 bölgesinin 2006-2010 yılları için elektrik ihtiyacını tahmin etmeye çalışmışlardır. Çalışmalarında ihracat, ithalat, nüfus ve bina yüzölçümü verilerini kullanarak yapay sinir ağları teknikleriyle doğruluk derecesi yüksek tahminde bulunmuşlardır.

Amber vd. (2018) binaların enerji ihtiyaçlarının her geçen gün arttığından bahsetmişlerdir. Bu nedenle güvenilir ve sağlam elektrik tüketimi tahmin modellerine ihtiyaç duyulduğu belirtilmiştir. Çalışmada çoklu regresyon, destek vektör makinesi, derin sinir ağı, yapay sinir ağı ve genetik programlama teknikleriyle Londra’da bulunan bir yönetim binasının elektrik tüketim tahmini yapılmıştır. Tahmin modelleri için sıcaklık, nem, rüzgâr, hafta içi gün indeksi parametrelerinin beş yıllık verileri kullanılmıştır. Yapay sinir ağlarının en iyi performansı gösterdiği sonucuna varılmıştır.

Çayır vd. (2018) çalışmalarında çeşitli sınıflama yöntemlerini kullanarak Londra’nın belirli bir bölgesindeki 30 konutun 3 yıllık elektrik tüketimini kullanarak geleceğe yönelik tüketim tahmininde bulunmuşlardır. Tatil günlerini ve mevsimsel etkileri de dikkate alarak yaptıkları çalışmada rastgele orman algoritmasının en iyi sonucu verdiğini görmüşlerdir.

Haliloğlu ve Tutu (2018) çalışmalarında elektrik enerjinin en büyük sıkıntısının depolanamaması olduğunu belirtmişlerdir. Enerji kaynaklarında genel olarak dışa bağlı olan ülkemizde elektrik ihtiyacının tahmin edilebilmesinin önemli olduğunu söylemişlerdir. Arzın talepten az ya da fazla olması durumlarının olumsuzluklarından bahsetmişlerdir. Yapılan tahmin çalışmalarının genellikle uzun dönem ihtiyacı olduğunu söyleyip ülkemiz için kısa dönemli günlük elektrik ihtiyacını tahmin etmeye çalışmışlardır. Çalışmalarında sıcaklığı bağımsız değişken ve elektrik tüketimini de bağımlı değişken olarak kullanmışlardır. Kısa dönemli tahmin için mevsimsel faktörlerin

önemli olduğunu belirtmişlerdir. Oluşturdukları modelle başarı oranı yüksek tahminde bulunmuşlardır.

Kar vd. (2018) çalışmalarında gelişmekte olan 15 ülkenin elektrik tüketimleriyle ekonomik büyümeleri arasında ilişkiyi çeşitli ekonometrik yöntemlerle ortaya koymaya çalışmışlardır. Enerji kaynaklarının gelişmiş ülkeler için öneminden bahsetmişlerdir. Enerji kaynakları arasında elektrik enerjisinin önemine dikkat çekmişlerdir. Temiz ve kullanımı kolay olan elektriğin pahalılığından ve üretimindeki zorluklardan bahsetmişlerdir. Çalışmalarında elektrik tüketimiyle ekonomik büyüme arasında uzun dönemli pozitif bir ilişki olduğu sonucuna varmışlardır. Sonuçların ülkelerin politikalarını belirlemede etkili olacağını söylemişlerdir.

Metin (2018) yüksek lisans tez çalışmasında ülkemizde elektrik tüketimini hangi değişkenlerin ne ölçüde etkilediğini test etmeye ve ülkemiz için uzun dönem elektrik tüketimini tahmin etmeye çalışmıştır. Ülkemiz Çin'den sonra elektrik tüketiminde en fazla talepte bulunan ülke konumundadır. Bu da ülkemizde her geçen gün elektrik tüketiminin arttığını göstermektedir. Elektrik tüketimini üretim olarak karşılama oranımız her geçen yıl azalma göstermektedir. Bu nedenle enerji bağımlılığını azaltacak çözümler geliştirilmelidir. Piyasanın dengelenmesi ve kullanıcıya dengeli fiyatta elektrik temini için gelecekteki tüketimlerin tahmin edilebilmesi önemlidir. 1975-2016 yılları arasındaki elektrik tüketim verileriyle nüfus, ithalat, ihracat ve GSYİH verileri kullanılarak yapay sinir ağları ile geleceğe yönelik elektrik tüketim tahmini yapılan çalışmada hata oranı düşük sonuçlar elde edilmiştir.

Özden ve Öztürk (2018) çalışmalarında özel bir endüstri bölgesinin ihtiyaç duyduğu elektrik enerjini tahmin etmeye çalışmışlardır. Endüstride üretimin devam edebilmesi için kesintisiz elektriğin sağlanması gerektiğini söylemişlerdir. Bu doğrultuda sınırlı veriyle yapay sinir ağları ve zaman serileri tekniklerini kullanarak kısa zamanlı elektrik ihtiyacını tespit etmeye çalışmışlardır. Yapay sinir ağı tekniğiyle elde edilen sonuçların daha güvenli olduğunu dile getirmişlerdir.

Ekinci (2019) çalışmasında ülkemizin gün geçtikçe ekonomik ve sosyal anlamda geliştiğini ve bu doğrultuda da elektrik tüketiminin arttığını ifade etmiştir. Ülkemizde elektrik ihtiyacının hangi kaynaklardan ne oranda elde edildiği ortaya konulmuştur.

Elektrik enerjisi talebinin mevsimsel, bölgesel ve anlık dalgalanmalar gösterebileceği belirtilmiştir. 1970-2015 arasındaki veriler kullanılarak kaynaklara göre detaylı analiz yapılmıştır. Çalışmada YSA ve ANFİS yöntemleri kullanılmış ve sonuçlar karşılaştırılarak kıyaslama yapılmıştır. ANFİS tahmin modellerinin gözlem sayısı ile ilişkili olduğu ve YSA yönteminin ise az veriyle daha iyi çalıştığı sonucuna varılmıştır.

Öksüz (2019) yapmış olduğu yüksek lisans tez çalışmasında elektrik dağıtım firmalarının üretim, dağıtım ve iletim konularında çalışmalar yapabilmeleri için talep edilecek elektrik enerjisini tahmin etmeleri gerektiğini dile getirmiştir. Çalışmasında Denizli ilindeki mesken abonelerinin 2008-2019 yılları arasındaki elektrik tüketim verileri ile sıcaklık, işsizlik, elektrik birim fiyatı değişkenlerini yapay sinir ağları tekniğiyle kullanarak 2019-2023 uzun dönem elektrik tüketim tahmininde bulunmaya çalışmıştır. Elde edilen sonuçlarla mevcut değerleri kıyaslamıştır.

Uzun (2019) yüksek lisans tez çalışmasında elektrik talep tahminlerinin sektörel ve zaman bazlı yapıldıklarını belirtmiştir. Elektrik ihtiyacını karşılamak için devlet ve özel sektör tarafından yatırımlar yapılmaktadır. Bu yatırımlar hem maliyetlidir hem de yatırımların karşılığını almak hemen mümkün olmamaktadır. Elektrik arz ve talebinin dengede devam etmesi gerekmektedir. Kullanıcılara ucuz ve kaliteli elektriğin sağlanması son derece önemlidir. Bu nedenlerle talep tahmin çalışmaları gün geçtikçe artmaktadır. Çalışmada geçmiş yıllara ait aylık elektrik tüketim verileri, mevsimsel hava verileri, nüfus ve büyüme verileri kullanılmıştır. Hem ülkemiz geneli hem de Bursa ili için orta ve uzun dönemli elektrik tüketim tahminleri yapılmıştır. Yapay sinir ağları ve çoklu doğrusal regresyon yöntemlerinin kullanıldığı çalışmada sonuçlar TEİAŞ'dan alın verilerle kıyaslanmış ve sonuçların paralellik gösterdiği görülmüştür.

Zolfaghari ve Sahabi (2019) elektrik tüketimi tahmini yaparken geleneksel modellerin yanında hibrit modellerden de faydalanıp kıyaslama yapmışlardır. Hibrit model olarak ARIMA ve GARC ailesi modellerini birleştiren bir yaklaşım benimsemişlerdir. Günlük elektrik tahminini yaz ve kış mevsimleri için ayrı ayrı olmak üzere 60 gün önceden tahmin eden bir yapı geliştirmeye çalışmışlardır. Sonuç olarak hibrit modelin geleneksel modellerden daha performanslı olduğunu söylemişlerdir.

Ercan vd. (2020) çalışmalarında ülkemizde elektrik enerjisinin hangi kaynaklardan temin edildiğini belirtmişlerdir. Kurulu gücümüzün kaynaklara göre dağılımı ortaya konmuştur. Yıllara göre kişi başı elektrik tüketiminden ve tüketim bazında dağılımdan bahsedilmiştir. Elektrik tüketimi için çeşitli ekonometrik ve istatistiksel yöntemler kullanılmaktadır. Hane halkı ve konut özellikleri karakteristikleri kullanılarak makine öğrenmesi yöntemleriyle elektrik tüketimi tahmin çalışması bulunmamaktadır. Bu çalışmada makine öğrenmesi yöntemleriyle hane halkı ve konut özellikleri kullanılarak konutların elektrik tüketimi tahmini bulunmaya çalışılmıştır.

Uzlu ve Dede (2020) çalışmalarında ülkemizdeki elektrik tüketimi tahmini için jaya algoritmasıyla eğitilmiş yapay sinir ağını kullanmışlardır. İthalat, ihracat ve nüfus verileri bağımsız değişkenler olarak kullanılmıştır. Kullanılan algoritma yapay arı kolonisi ve öğretim öğrenme tabanlı optimizasyon algoritmaları ile test edilmiştir. Sonuçlar TEİAŞ'dan alınan verilerle karşılaştırılmış ve yapılan tahminin doğruluğunun yüksek olduğu görülmüştür.

Özkan vd. (2020) çalışmalarında elektrik enerjisinin benzersiz özelliklere sahip olduğunu belirtmişlerdir. Kısa, orta ve uzun vadeli tahminlerin hangi amaçlarla kullanıldığı ifade edilmiştir. Zaman serisi analizinde kullanılan iki tahmin modeli kullanılıp hangisiyle en verimli sonuca ulaşıldığı ortaya konmuştur. Ocak 2016-Aralık 2018 aralığı elektrik tüketim tahmini için 12, 24 ve 36 aylık tüketim verileri esas alınmıştır. Winters yönteminin ve en küçük kareler yöntemi ile Fourirer analizi yönteminin kullanıldığı çalışmada winters yöntemi ile daha iyi tahminde bulunulmuştur.

Pekmezci (2020) yapmış olduğu çalışmada zaman serileri yöntemi ile farklı alanlarda geleceğe yönelik tahin yapılmasının mümkün olduğundan bahsetmiştir. Ancak bu yöntemle tahmin yapılırken veri ön işleme aşamasında bazı eksikliklerin ortaya çıkması mümkündür. Bu sorunu en aza indirmek için veri ön işleme aşamasında dalgacık dönüşümü kullanılabilir. Çalışmada 26 ülke için 1960-2014 yıllarını kapsayan kişi başı elektrik tüketim verileri kullanılarak dalgacık dönüşümüne dayanan ARIMA modeliyle elektrik tüketimi tahmini yapılmıştır. Geleneksel yöntemlerle yapılan karşılaştırmalar sonucu yöntemin başarılı olduğu görülmüştür.

Pençe vd. (2020) çalışmalarında ülkemizdeki elektrik tüketiminde en büyük payın sanayi sektörüne ait olduğunu belirtmişlerdir. Sanayideki gelişmeler ile teknolojik gelişmelerin birbirine paralel olması gerektiğini ifade edip gelecekte gerekli olan elektrik tüketim miktarının tahmin edilerek alınması gereken önlemlerin şimdiden hayata geçirilmesinin önemine dikkat çekmişlerdir. Çalışmalarında 1970-2016 yılları arasındaki sanayide tüketilen elektrik verilerini kullanarak yapay sinir ağı sistemiyle 2017-2023 yılı için gerekli olan elektrik miktarını bulmaya çalışmışlardır. Bulmuş oldukları tüketim değeri ile Türkiye Elektrik İletim A.Ş. Genel Müdürlüğünün tahminlerinin paralellik gösterdiğini söylemişlerdir.

Shibano ve Mogi (2020) birçok çalışmanın ülkenin tamamındaki elektrik tüketimini tahmin etmeye yönelik olduğunu ancak ülkenin belirli bir bölgesindeki elektrik tüketimini tahmin etmek için uygun olmadığını belirtmişlerdir. Örneğin Afrika'daki insanların %55'inin elektriğe erişiminin olmadığı ifade edilmiştir. Bu nedenle tarihsel verilere dayanarak elektriğin verilmediği bölgeler için bir genelleme yapılarak elektrik tüketim tahmini yapılmasının doğru olmadığı söylenmiştir. Belirli bir bölgenin yıllık elektrik tüketimini tahmin etmek için hane halkı geliri elektrik tüketim modeli adında yeni bir model geliştirilmiş ve bazı hane gruplarının elektrik tüketimini toplanarak, grubun elektrik tüketimi tahmin edilmiştir. Tanzania'nın belirli bölgelerine uygulanan model sonrası tüm bölgeler için sonuçlar toplanarak genel bir toplam tüketim elde edilmeye çalışılmıştır.

Şahin (2020) çalışmasında elektrik enerjisinin talepten fazla arz ya da talepten düşük arz edilmesinin sorunlara yol açacağını belirtmiştir. Elektrik enerjisinin depolanamadığından üretilen enerjinin sisteme dâhil edilip harcanması gerektiğini söylemiştir. İhtiyaç duyulan elektriğin temin edilememesi durumunda ülkemizde çeşitli alanlarda gelişimin yavaşlayacağını ve ihtiyaçtan fazla elektriğin temininde ise israfın ortaya çıkacağını belirtip elektrik ihtiyacının olabildiğince doğru tahmin edilmesi gerektiğini ifade etmiştir. GSYİH, trafo sayısı, nüfus ve elektrik üretimine yapılan yatırımı değişken olarak kullanıp yapay sinir ağı uygulamalarından çok katmanlı model ile geleceğe yönelik tahminde bulunmuştur.

Agyare vd. (2021) çoğu ekipmanın işlevini tam olarak yerine getirebilmesi için elektriğin kaçınılmaz olduğunu söylemişlerdir. Çalışmalarında bir maden topluluğu olan Tarkwa'da

2019 yılı elektrik tüketimi tahmini yapabilmek için 2018 yılı aylık verileri kullanılmıştır. ANFIS ve ARIMA modellerinin kullanıldığı çalışmada ANFIS modeliyle daha iyi sonuç elde edildiği görülmüştür. 2019 yılı tüketiminin bir önceki yıla göre %14 artış göstereceği öngörülmüştür.

Er ve Karaca (2021) çalışmalarında günümüzde elektriğin olmamasının katlanılamaz bir hal alacağından bahsetmişlerdir. Karadeniz'deki 18 ilin elektrik tüketim tahmini 3 farklı yolla yapılmaya çalışılmıştır. Aylık elektrik tüketim tahmini için ithalat, ihracat, sıcaklık, kurulu güç elektrik üretim verileri bağımsız değişkenler ve elektrik tüketim verileri de bağımlı değişken olarak kullanılmıştır. Destek vektör regresyon, çoklu doğrusal regresyon ve rasgele orman regresyon yöntemleri kullanılarak 18 il için ayrı ayrı tüketim tahmininde bulunulmuştur. Rasgele orman regresyonunun diğer iki yönteme göre daha iyi sonuç verdiği gözlemlenmiştir.

Gao vd. (2021) enerji kayıplarının önüne geçebilmek ve güç sistemlerini geliştirebilmek için elektrik şirketlerinin elektrik tüketimlerini önceden doğru bir şekilde tahmin etmeleri gerektiğini söylemişlerdir. Çalışmada günümüzde yaygın olarak kullanılan elektrik tahmin modellerinden bahsedilmiş ve güç tahmin problemlerini incelemek için derin öğrenme teknolojilerinden faydalanılmıştır. Jiangsu eyaletindeki 2005-2019 yılları arası elektrik tüketim verileri kullanılarak hibrit modelle ARIMA ve derin sinir ağı modelleri karşılaştırılmıştır. Sonuç olarak hibrit modelin diğer modeller kadar doğru sonuç vermediği ortaya konmuştur.

Kamber vd. (2021) çalışmalarında kısa dönemli elektrik tüketim tahminlerinin popülerliğinden bahsetmişlerdir. Basit istatistiksel hesaplamalarla elektrik tüketim tahmini yapmak oldukça güçtür. Elektrik enerjisi büyük oranda depolanamadığı için talebe göre gerçek zamanlı olarak üretim yapılmalıdır. 2015-2018 yılları arasındaki İspanyanın 5 büyük şehrinin saatlik elektrik üretim ve tüketim verileri kullanılarak yapay sinir ağlarıyla kısa süreli elektrik tüketim tahmininde bulunulmaya çalışılmıştır. Çalışmada tekrarlı sinir ağı mimarisi olan LSTM ile başarılı tahminler yapılmıştır.

Nebati vd. (2021) çalışmalarında dünya nüfusunun artışıyla elektrik enerjisine olan talebin artışı ve kaynak sıkıntısını dile getirmişlerdir. Elektrik enerjisinin depolanmasının zor olmasından dolayı talep doğrultusunda enerjinin tedarik edilmesinin

daha doğru olacağını belirtmişlerdir. Bu nedenle ülkemizdeki 1970-2019 yılları arasındaki elektrik tüketimlerini kullanarak regresyon analiziyle 2035 yılı için ihtiyaç duyulan elektrik enerjisini tahmin etmeye çalışmışlardır.

Özdemir (2021) çalışmasında 2 hafta ile 3 yıl arasındaki tahminlerin orta dönem elektrik enerjisi tahmini olduğunu belirtmiştir. Doğrusal ve doğrusal olmayan nedenler elektrik enerjisi tüketimi tahminini zorlaştırmaktadır. Orta dönemli elektrik tüketim tahmini güç sistemlerinin bakımı için oldukça önemlidir. Ayrıca orta dönemli tahminler yenilenebilir enerji teknolojileriyle ilgili yatırımlar içinde önemli bilgiler sunmaktadır. Çalışmada İskenderun bölgesinin orta dönemli elektrik ihtiyacı tahmini için yapay sinir ağlarından faydalanılmıştır. Tahmin için 2011-2022 yılları arasındaki aylık ortalama elektrik tüketimi ve aylık ortalama sıcaklık verileri kullanılmıştır. Sonuç olarak YSA ile başarılı tahmin yapıldığı görülmüştür.

Priyadarshana vd. (2021) geliştirmekte olan Sri Lanka'da hanelerin %98'inin elektriğe sahip olduğunu ve halkın elektrik kesintilerinden mustarip olduğunu belirtmişlerdir. İhtiyacın bilinmesi halinde elektrik arzının sağlanmasıyla bu durumun önüne geçilebileceği ifade edilmiştir. Bu nedenle hava etmenleri de değerlendirilerek Sri Lanka için aylık elektrik tüketimi tahmin edilmeye çalışılmıştır. Dördü ekonometrik olmak üzere sekiz tahmin yaklaşımının kullanıldığı çalışmada nedensellik ilişkilerini yakalamaya yarayan ARDL modeli ile daha iyi performans elde edilmiştir.

Ramos vd. (2021) elektrik tüketim tahmini yapılırken farklı yöntemlerin veri setleri üzerindeki doğruluklarını karşılaştırmak yerine, elektrik tüketimi tahmini yaparken her bir bina için en uygun tekniği tanımlayan bağlamsal bir yaklaşımla konunun ele alınması gerektiğini belirtmişlerdir. Bu doğrultuda 72 algoritma test edilmiştir. Yapay sinir ağları ve destek vektör makineleriyle verimli sonuçlar alınmıştır.

Sigeze (2021) yapmış olduğu çalışmada ülkemizde artan elektrik tüketimindeki hanelerin payını incelemiştir. Elektrik tüketiminde sanayiden sonraki büyük payın konutlara ait olduğunu ifade etmiştir. Hanelerin elektrik tüketiminin incelerken hanedeki kişi sayılarını, kişilerin özelliklerini ve hane büyükleriyle birlikte hanelerde kullanılan elektrikli araçları dikkate almıştır. Doğrusal regresyon ve probit modeli olmak üzere iki aşamalı model kullanmıştır. 11818 hane üzerinde yapılan çalışmada elektrik tüketimine hane reisinin

yaşının, hane halkının gelirinin ve hane büyüklüğünün pozitif etki ettiğini ortaya koymuştur.

Ülkü ve Yalpir (2021) çalışmalarında ülkemizdeki elektrik üretimindeki yerli ve ithal kaynaklı üretim oranlarını paylaşmışlardır. Ülkeler arasındaki en önemli rekabet unsurlarından biri enerjidir. Enerji kaynakları arasında elektrik enerjisinin ayrı bir önemi vardır. Elektrik enerjisi diğer enerji kaynaklarından dönüşümle elde edilir ve depolanamaz. Bu nedenle ihtiyacın bilinmesi gerekir ki kesintisiz arz sağlanabilsin. Ülkemizde elektrik enerjisine olan ihtiyaç bulunmaya çalışılırken unsular genel olarak değil her il için ayrı ayrı değerlendirilmeye çalışılmıştır. Yapay sinir ağlarının ve çoklu regresyon analizinin kullanıldığı çalışmada eğitim durumu, nüfus, ithalat, ihracat, GSYİH ve sanayi verileri girdi olarak ve elektrik tüketimi de çıktı olarak kullanılıp ülkemizin 2030 yılı için elektrik enerjisi ihtiyacı tahmin edilmeye çalışılmıştır.

Botman vd. (2022) çalışmalarında eksik verilere rağmen uzun dönemli hane halkı tüketimini tahmin etmeye yarayan bir yöntem geliştirmeye çalışmışlardır. Önerilen yaklaşım düşük hesaplama karmaşıklığı sayesinde ölçeklenebilir özelliğe sahiptir. Hanenin bir önceki yılına ait en az bir aylık verisi ile bir sonraki yılın tüketimi tahmin edilebilmektedir. Haneye özgü veriler ya da hava durumu verilerine ihtiyaç duyulmaz. Geliştirilen model mutlak tüketim kalıpları yerine göreceli tüketim kalıplarıyla çalışır. Öncelikle veriler üzerinde ön işleme, veri artırma ve normalleştirme işlemleri yapılır. Sonra kümeleme ve oranlara dayalı tahmin yapılır. Son olarak toplu öğrenme ve son işleme adımları uygulanarak sonuca ulaşılır.

Pavlicko vd. (2022) Slovak elektrik dağıtım şirketinin resmi elektrik tahmininden daha doğru saatlik maksimum elektrik ihtiyacını tahmin edebilen modelleri önermeye çalışmışlardır. Dünyanın her yerinde olduğu gibi Slovakya’da da otomasyon ve robotlaşmanın artmasıyla elektrik tüketiminin gün geçtikçe arttığı belirtilmiştir. Elektrik enerjisinin depolanamadığından arz ve talep arasında dengenin ortaya konmasının öneminden bahsedilmiştir. Enine gri modeller, doğrusal olmayan gri bernoulli modeller, çok katmanlı ileri beslemeli geri yayılım ağı ve hibrit modellerle çalışmalar yapılmış ve en iyi sonuç hibrit modelle alınmıştır.

Velasquez vd. (2022) elektrik tüketim tahmininin elektrik sistemlerinin genişletilmesi ve santrallerin kurulu güce göre kullanılabilirliği açısından önemli olduğunu belirtmişlerdir. Çalışmada öncelikle 2014-2019 yılları gerçek verileriyle elektrik talebinin hata yüzdesi analiz edilmiştir. Daha sonra zaman serisi modelleri kullanılarak Brezilyanın farklı bölgeleri için 2021-2025 yılları elektrik ihtiyacı bulunmaya çalışılmıştır.

Zou ve Sun (2022) çalışmalarında işletmelerin ekonomik büyümesi için elektriğin itici bir güç olduğunu belirtmişlerdir. Güç tüketimini de işletme yönetimi için önemli bir referanstır. Elektrik tüketim tahmini için geleneksel yöntemler doğrusal olmayan problemlerin çözümü için yetersiz kalmaktadır. Akıllı tahmin modelleri de veri setlerine göre zaman zaman kararsız kalabilmektedir. Bu çalışmada işletmeler için daha önceden yapılan orta vadeli tahmin çalışmaları incelenmiştir. Hava durumu, tatil günleri, rüzgâr hızı gibi veriler dikkate alındığında tahmin çalışmaları için NPCNN-BLSTM hibrit sinir ağı modeli önerilmiştir.

3. KURAMSAL TEMELLER

3.1. Enerji


Enerjinin birçok tanımı vardır. Kelime olarak iş ve çalışma anlamlarına gelmektedir. Enerji bir nesnenin iş yapabilme yeteneği olarak tanımlanabilir. Fiziksel sistemlerin çalışmasını sağlayan temel bir kavramdır. Enerji yaşamsal bir öneme sahiptir (Yavaş, 2018). Temel olarak enerji ikiye ayrılır. Bunlar kinetik enerji ve potansiyel enerjidir. Kinetik enerji cismin hareketinden dolayı sahip olduğu enerjyken, potansiyel enerji ise cismin konumundan dolayı sahip olduğu enerjidir. Kinetik ve potansiyel enerji haricinde kimyasal, nükleer, ısı ve elektrik enerjileri de bulunur. Enerjinin korunum ilkesine göre ne yoktan var edilebilir ne de yeniden yaratılabilir. Enerji bir formdan başka forma dönüştürülebilir. Buna enerjinin korunumu yasası denir (Gülçiçek ve Yağbasan, 2014). Enerji çeşitli süreçler aracılığıyla transfer edilebilir ve dönüştürülebilir. Örneğin, bir jeneratör kinetik enerjiyi elektrik enerjisine dönüştürebilir. Diğer bir örnek ise termik santrallerde kimyasal enerjinin elektrik enerjisine dönüştürülmesidir. Enerji genellikle joule (J) cinsinden ölçülür. Diğer ölçüm birimleri arasında kilowatt saat (kWh) ve kalori bulunur. Bazı enerji formları, mekanik, radyant, güneş, kimyasal, nükleer, rüzgâr ve elektrik enerjisi olarak sıralanabilir (Töman ve Çimen, 2011).

Enerji, günlük yaşamda, sanayide, ulaşım ve teknolojiye geniş bir yelpazede kullanılır. Enerji kullanımının çevresel ve ekonomik etkileri de büyüktür. Enerji, evrendeki temel kavramlardan biridir ve fizik, mühendislik, çevre bilimi ve ekonomi gibi birçok alanda önemli bir rol oynar. Bu çalışmanın konusu itibarıyla elektrik enerjisi üzerinde durulacaktır.

3.2. Enerji Kaynakları ve Türleri

Enerjinin elde edilmesi veya üretilmesi için kullanılan kaynağa enerji kaynağı denir. Enerji kaynakları insanların ihtiyaçlarını karşılamak üzere farklı formlarda kullanılır. Enerji kaynakları kullanışlarına ve dönüştürülebilirliklerine göre çeşitli sınıflara ayrılırlar. Kullanışlarına göre yenilenebilir (tükenir) ve yenilenemez (tükenmez),

dönüştürülebilirliklerine göre ise birincil ve ikincil enerji kaynakları olarak adlandırılırlar (Koç ve Kadir, 2015).



Şekil 3.1. Enerji Kaynaklarının Sınıflandırılması

3.2.1. Yenilenemez enerji kaynakları

Bu kaynaklar insanlar tarafından kullanıldıkça tükenirler. Sürdürülebilirlikleri yoktur. Genellikle kullanımları çevre sorunlarına neden olurlar. Bu enerji kaynaklarının tükenmesi kaçınılmazdır.

3.2.2. Yenilenebilir enerji kaynakları

Yenilenemez enerji kaynaklarının aksine sürdürülebilirlikleri mümkündür. Yapıları itibariyle sürekli üretilebilirler ve tükenmezler. Doğal bir çevrim sürecinde aynı olarak kalırlar ve azalmazlar. Çevresel etkileri çok daha azdır. Enerji yerel olarak üretilebildiği için ülkelerin bağımsızlığı açısından son derece önemlidir (Baysal ve Daşdemir, 2023).

3.2.3. Birincil enerji kaynakları


Herhangi bir dönüşüme uğramamış enerji kaynaklarıdır. Doğada bulundukları şekilde kullanılırlar. Birincil enerji kaynağı yenilenebilir veya yenilemez olabilir. Bu kaynaklar enerji üretiminin başlangıcını oluştururlar. Birincil enerji kaynakları dönüştürülerek farklı amaçlarla kullanılırlar (Yüklü ve İçerli, 2023).

3.2.4. İkincil enerji kaynakları

Birincil enerji kaynaklarından elde edilirler. Birincil enerji kaynakları işlenerek veya dönüştürülerek ihtiyaç duyulan enerji kaynakları ortaya çıkarılır. Birincil enerji kaynaklarından dönüşümlerle elde edilen ikincil enerji kaynakları insanların günlük ihtiyaçlarını karşılamalarına yardımcı olur. Yaşantımızı sürdürebilmemiz için ihtiyaç duyduğumuz en önemli enerji kaynaklarından biri olan elektrik enerjisi ikincil enerji kaynağıdır (Yüklü ve İçerli, 2023).


3.3. Dünya’da Enerji Tüketimi

Ülkelerin ilerlemesini sağlayan en önemli faktörlerden biri enerjidir. Sanayideki gelişmeler ve dünya nüfusunun artışı enerjiye olan ihtiyacı gün geçtikçe artırmaktadır. Önceleri fosil yakıtlardan sağlanan enerji ihtiyacına günümüzde yenilenebilir kaynaklardan sağlanmasına öncelik verilmeye başlanmıştır (Koç vd., 2018). Şekil 3.2’deki grafik incelendiğinde dünya genelindeki çeşitli fosil kaynakların tükeneceği tarihler öngörülmektedir. Grafiğe göre petrolün 2050, doğalgazın 2060 ve kömürün 2080’li yıllarda tükeneceği tahmin edilmektedir.



Şekil 3.2. Fosil Yakıt Rezervleri ve Gelecek Tahminleri (Görgülü, 2022)


Fosil yakıtların rezervleri sınırsız olmadığından enerjinin yenilenebilir kaynaklardan elde edilmeye çalışılması son derece normaldir. Teknolojinin ilerlemesiyle gün geçtikçe yenilenebilir kaynaklardan daha verimli şekilde enerji elde edilmesi gerçekleşmektedir. Şekil 3.3'deki grafik incelendiğinde dünyada 2021 yılında yenilenebilir enerji kaynaklarına göre kurulu güç dağılımları görülmektedir.



Şekil 3.3. 2021 Yılı Dünya'da Yenilebilir Enerjiye Dayalı Kurulu Güç Dağılımı (Özbektaş vd.,2023)


BP'nin yayımlamış olduğu “2022 Dünya Enerji İstatistikleri Raporuna” göre bazı enerji gelişmeleri şu şekildedir. 2021 yılında birincil enerji talebi %5,8 artış göstererek 2019 yılı seviyelerini %1,3 oranında aşmıştır. 2019 yılında fosil yakıtlar enerji talebinin %83'ünü karşılarken 2021 yılında %82'sini karşılamıştır. Elektrik üretiminde yenilenebilir enerji kaynaklarından daha fazla faydalanılmaya başlanmıştır. Enerji yoğunluğunun ve karbon emisyonunun 2021 yılında iyileşme göstermediği görülmüştür. 2021 yılı petrol talebi 2019 yılına göre daha az olmuştur. Doğalgaz talebi ise 2021 yılında önceki yıla göre %5,3 oranında artış göstermiştir. Kömür tüketiminde de 2021 yılında %6 artış olduğu tespit edilmiştir. 2021 yılında elektrik üretiminde %6,2 artış görülmüştür. Elektrik üretiminde rüzgâr ve güneş enerjisinin payı %10,2'ye ulaşmıştır. İlk defa rüzgâr ve güneş enerjisinin küresel güce olan katkısının nükleer enerjiden daha fazla olduğu görülmüştür. Yenilenebilir enerji kaynaklarının payı enerji üretiminde %13 seviyelerine ulaşmıştır(BP, 2022).

Bazı ülkelerdeki enerji tüketimleri kişi sayısına göre oranlandığında Şekil 3.4'de ki grafik ortaya çıkmıştır. Grafik incelendiğinde kişi başına düşen enerji tüketimlerinin ülkelerin gelişmişlik düzeylerine, iklimlerine, nüfuslarına göre değişim gösterdiği görülmektedir. UEA'nın yayımladığı 2023 raporuna göre küresel enerji yoğunluğu 2022 yılında %1,3 ilerleme kaydetmiştir. 2020 yılından bu yana temiz enerjiye yapılan yatırımlar %40 düzeyinde artış göstermiştir. Temiz enerjideki artışa karşılık fosil yakıtlardan üretilen enerji miktarının da düştüğü görülmektedir (IEA, 2023).



Şekil 3.4. Bazı Ülkeler İçin Kişi Başına Düşen Enerji Tüketimi (Wikipedia, 2023)

Şekil 3.5’de dünyadaki enerji kaynaklarının dağılımı görülmektedir. Özellikle pandemi dönemi enerji kaynaklarının arz talep dengesine etkileri olmuştur. 2020 yılında birincil enerji kaynakları %4,5 oranında düşüş göstermiştir. Pandemi dönemi arz düşüşünden sonra artan arz sonrası kaynakların talebe yetişemediği görülmüştür. Özellikle enerjide dışa bağımlı olan ülkeler için bu durum daha büyük bir sorun olmuştur.




Şekil 3.5. 2019 Yılı Dünya’da Enerji Kaynakları Dağılımı (IEA, 2019)

3.4. Türkiye’de Enerji Tüketimi

Ülkemizde ithalat giderlerinin dörtte biri enerji ihtiyacını gidermek için yapılmaktadır. İthalatla alınan enerjinin ise dörtte üçü ülkemizin enerji ihtiyacını karşılamaktadır. Ülkemizde petrol ve doğalgaz rezervlerinin yetersiz olması, yenilenebilir enerji kaynaklarından yeteri kadar faydalanılamaması nedeniyle enerji ihtiyacının büyük bir kısmı yurt dışından karşılanmaktadır (Yılankırkan ve Doğan, 2023)

Şekil 3.6 incelendiğinde ülkemizdeki 2020 yılı enerji tüketimleri 1990 yılına göre yaklaşık 3 kat artış göstermiştir. 2020 yılında enerji tüketiminde en fazla payı mesken ve hizmet sektörünün sonrasında ise sanayi sektörünün aldığı görülmektedir.




Şekil 3.6. Ülkemizde Yıllara ve Sektörlere Göre Enerji Tüketimi (ETKB 1, 2023)

Ülkemizde elektrik enerjisi tüketimi 2022 yılında bir önceki yıla göre %0,5 oranında düşüş göstererek 331,1 TWH olmuştur. Elektrik üretimi ise bir önceki yıla göre yine %1,9 oranında düşüş göstererek 328,3 TWH olmuştur. 2022 yılında elektrik üretimimizin, %34,6'sı kömürden, %22,9'u doğal gazdan, %20,3'ü hidrolik enerjiden, %10,6'sı rüzgârdan, %5,1'i güneşten, %3,4'ü jeotermal enerjiden ve %3'ü diğer kaynaklardan elde edilmiştir.

Ülkemizde 2022 yılında 3,58 milyon ton ham petrol üretimi yapılmasına karşın 33,49 milyon ton ham petrol ithalatı yapılmıştır. Bu verilerden yola çıkarak ülkemizin %90 oranında ham petrol ithalatına bağımlı olduğu sonucuna varılmaktadır. Ülkemizde 2022 yılında 408 milyon m³ doğal gaz üretimi yapılmasına karşın 54,6 milyar m³ doğal gaz ithalatı yapılmıştır. Bu verilerden yola çıkarak ülkemizin %99 oranında doğal gaz ithalatına bağımlı olduğu sonucuna varılmaktadır.

3.5. Türkiye’de Enerji Potansiyeli

Türkiye, enerji potansiyeli açısından çeşitli kaynaklara sahip bir ülkedir. Ülkemizdeki yenilenebilir enerji kaynaklarının oranı %52 iken, fosil enerji kaynaklarının oranı %48’dir. Ülkemizdeki yenilenebilir enerji kaynaklarının kendi içindeki dağılımı da Şekil 3.7’de verilmiştir.



Şekil 3.7. Ülkemizdeki Yenilenebilir Enerji Kaynaklarının Kendi İçindeki Dağılımı (JKBB, 2023)

Ülkemizdeki enerji potansiyeli ile ilgili bazı ana unsurlar ve açıklamaları şu şekildedir:

- Güneş Enerjisi Potansiyeli:** Türkiye, güneş enerjisi açısından zengin bir ülkedir. Özellikle Güneydoğu Anadolu Bölgesi ve Akdeniz Bölgesi'nde güneş enerjisi potansiyeli yüksektir. Güneş enerjisi panellerinin kurulumu ve güneş enerjisi santrallerinin inşası, bu potansiyelin değerlendirilmesine yönelik önemli bir alandır.
- Rüzgar Enerjisi Potansiyeli:** Türkiye, özellikle Ege ve Marmara kıyıları ile İç Anadolu Bölgesi'nde rüzgar enerjisi potansiyeli yüksektir. Rüzgâr enerjisi türbinleri, elektrik üretimi için kullanılarak sürdürülebilir enerji kaynaklarına katkı sağlar.
- Hidroelektrik Potansiyel:** Türkiye'nin birçok akarsu ve nehir sistemi, hidroelektrik enerji üretimi için potansiyel sunar. Bu tesisler suyun potansiyel enerjisini elektriğe dönüştürür.
- Termal Enerji Kaynakları:** Türkiye, jeotermal enerji kaynakları bakımından da zengindir. Kaplıcalar ve jeotermal enerji üretimi için kullanılan kaynaklar, sıcak su ve buharın enerji üretiminde kullanılmasını sağlar.

5. **Kömür ve Doğalgaz Kaynakları:** Türkiye, yer altı kömür rezervleri ve doğalgaz kaynaklarına sahiptir. Bu fosil yakıtlar enerji üretimi için kullanılır.
6. **Nükleer Enerji Potansiyeli:** Türkiye, nükleer enerji üretimi için inşa edilen nükleer santraller ile nükleer enerji potansiyeline sahiptir. Bu santraller elektrik üretiminde kullanılır.

Türkiye, enerji potansiyelini çeşitli enerji kaynaklarından elde etme konusunda büyük bir çaba sarf etmektedir. Sürdürülebilir enerji kaynaklarına yönelik yatırımların artırılması, enerji verimliliği çalışmalarının geliştirilmesi ve enerji politikalarının yenilenebilir kaynaklara dayalı olarak şekillendirilmesi, Türkiye'nin enerji ihtiyaçlarını karşılarken çevresel sürdürülebilirliği artırmayı hedeflemektedir.


3.6. Elektrik Enerjisi

Elektrik enerjisi, elektronlar arasındaki elektriksel potansiyel farkın sonucu olarak oluşan bir enerji türüdür. Elektrik enerjisi, hareket eden yüklerin elektriksel alan içindeki hareketinden kaynaklanır. Elektronlar, bir elektriksel devre içinde akış halindeyken bu enerji taşınır (Eke ve Ayrancı, 2018). Temelde, elektrik enerjisi elektriksel iş yapma yeteneği olarak tanımlanabilir. Bu enerji, aydınlatma, ısınma, elektronik cihazların çalıştırılması, makinelerin işlemesi ve birçok günlük uygulama için kullanılır. Elektrik enerjisi, enerjinin dönüşümü, iletimi ve kullanımı konusunda büyük bir öneme sahiptir ve modern yaşamın ayrılmaz bir parçasıdır. Elektrik enerjisi, elektrik santrallerinde üretilir ve iletim hatları aracılığıyla tüketim noktalarına taşınır.

Enerji kaynakları arasında elektrik enerjisi hayatın her alanında en çok ihtiyaç duyulan enerji türü olması ve avantajları dolayısıyla dünyada en çok kullanılan enerji türüdür (Karabulut, 2004). Elektrik enerjisi ikincil enerji kaynağıdır. Doğada direkt olarak bulunmaz. Birincil enerji kaynaklarından dönüştürülerek elde edilir. Fosil yakıtların terk edilmeye başlamasıyla elektrik enerjinin ana vektörü haline gelmeye başlamıştır. Günümüzde daha ön plana çıkan elektriğe gelecekte daha fazla ihtiyaç duyulacağı bir gerçektir.

3.7. Elektrik Enerjisi Kullanımının Sektörlere Göre Dağılımı

Dünyada elektrik enerjisi kullanımının sektörlere göre dağılımı, farklı ülkeler ve bölgelere göre değişebilir. TEDAŞ tarafından hazırlanan Şekil 3.8’de ki grafik incelendiğinde 2020 yılında dünyada elektrik enerjisinin en fazla sanayi sektöründe harcandığı görülmektedir.



Şekil 3.8. Dünya Elektrik Tüketimi Sektörel Dağılımı (TEDAŞ, 2023)

Genel olarak aşağıdaki ana sektörlerde kullanımın yoğunlaştığı görülmektedir:


- Sanayi Sektörü:** Sanayi sektörü, dünyadaki elektrik tüketiminin önemli bir bölümünü oluşturur. Fabrikalar, üretim tesisleri, madencilik ve endüstriyel işletmeler elektrik enerjisi kullanımının büyük bir kısmını temsil eder.
- Konut ve Ticari Sektör:** Elektrik enerjisi, konutlar, ofisler, alışveriş merkezleri, oteller ve benzeri ticari binalarda geniş bir kullanım alanı bulur. Bu sektör, ısıtma, soğutma, aydınlatma, ev aletleri ve elektronik cihazların kullanımı için elektrik tüketir.
- Ulaştırma Sektörü:** Elektrik enerjisi, elektrikli araçlar, trenler, tramvaylar ve metro sistemleri gibi ulaşım araçlarında giderek daha fazla kullanılmaktadır. Elektrikli taşıtların popülaritesi arttıkça, bu sektördeki elektrik tüketimi de artmaktadır.
- Tarım Sektörü:** Sulama sistemleri, sera ısıtma ve diğer tarım uygulamaları için elektrik enerjisi kullanılır. Tarım sektörü, bazı bölgelerde elektrik enerjisi tüketiminin önemli bir kısmını oluşturabilir.

5. **Kamu Sektörü:** Kamu hizmetleri, hastaneler, okullar, hükümet binaları ve diğer kamu binaları elektrik enerjisi kullanır. Elektrik enerjisi, bu sektörlerde aydınlatma, ısıtma, soğutma ve elektronik ekipmanların çalıştırılması için önemlidir.
6. **Diğer Sektörler:** Elektrik enerjisi aynı zamanda diğer özel sektörlerde de kullanılır. Bunlar arasında iletişim, eğlence, hizmetler ve eğitim gibi farklı sektörler yer alır.

Her ülkenin elektrik tüketimi dağılımı farklıdır ve bu dağılım, bir ülkenin endüstriyel gelişimi, enerji politikaları, enerji kaynakları ve demografik faktörlere bağlı olarak değişebilir. Sektörel elektrik enerjisi tüketimi, enerji verimliliği, sürdürülebilirlik ve enerji yönetimi konularında stratejilerin belirlenmesi ve enerji politikalarının geliştirilmesinde önemli bir rol oynar.

3.8. Türkiye’de Elektrik Üretimi ve Elektrik Kurulu Gücü

Ülkemizde sektörlerdeki elektrik tüketimi 2020 yılında 1990 yılına göre yaklaşık 5 kat artış göstermiştir. Sektör olarak bakıldığında ise elektrik tüketiminin 2020 yılında en fazla sanayide ve hizmet sektöründe yapıldığı görülmektedir.



Şekil 3.9. Ülkemizde Yıllara ve Sektörlere Göre Elektrik Enerjisi Tüketimi (CSB, 2023)

2022 yılında elektrik üretimimizin, %34,6'sı kömürden, %22,9'u doğal gazdan, %20,3'ü hidrolik enerjiden, %10,6'sı rüzgardan, %5,1'i güneşten, %3,4'ü jeotermal enerjiden ve %3'ü diğer kaynaklardan elde edilmiştir. 2023 yılı Eylül ayı sonu itibarıyla ülkemiz

kurulu gücü 105.668 MW'a ulaşmıştır. 2023 yılı Eylül ayı sonu itibarıyla kurulu gücümüzün kaynaklara göre dağılımı; %29,9'u hidrolik enerji, %24,0'ı doğal gaz, %20,6'sı kömür, %11'i rüzgâr, %10,3'ü güneş, %1,6'sı jeotermal ve %2,6'sı ise diğer kaynaklar şeklindedir. Ayrıca Ülkemizde elektrik enerjisi üretim santrali sayısı, 2023 yılı Eylül ayı sonu itibarıyla 12.562'ye (lisanssız santraller dâhil) yükselmiştir. Mevcut santrallerin 753 adedi hidroelektrik, 68 adedi kömür, 363 adedi rüzgâr, 63 adedi jeotermal, 343 adedi doğal gaz, 10.479 adedi güneş, 493 adedi ise diğer kaynaklı santrallerdir (ETKB 2, 2023)

2022 yılı Türkiye Ulusal Enerji Planına göre ülkemizde 2000 yılında 128 TWh olan elektrik tüketimi %4,4 artışla 2020 yılında 306,1 TWh tüketime ulaşmıştır. Bu değer %3,5 artışla 2035 yılında 510,5 TWh tüketime ulaşması öngörülmektedir. 2035 yılında elektrik kurulu gücümüzün de 189,7 GW'a yükselmesi hedeflenmektedir. 2020 yılında kurulu güç içerisindeki oranı %52 olan yenilenebilir enerji kaynaklarının 2035 yılında %64,7'ye ulaşması beklenmektedir (ETKB 3, 2023)


3.9. Enerji Verimliliği

Enerji üretiminde kullanılan fosil kaynakların dünya genelinde tükenmeye başlaması ve yenilenebilir enerji kaynaklarından da yeterli düzeyde enerji elde edilememesi sonucu enerjinin kıymeti anlaşılmış ve enerji daha verimli kullanılmaya başlanmıştır (Doğan ve Yılankırkan, 2015). Enerji verimliliği, enerji kullanımını en aza indirirken aynı hizmet düzeyini veya üretim çıktısını sürdürme yeteneğidir. Bu, daha az enerji tüketerek aynı sonuçları elde etmek anlamına gelir. Enerji verimliliği, sürdürülebilirlik, çevresel koruma ve enerji maliyetlerinin düşürülmesi açısından kritik bir rol oynar. Ayrıca, enerji güvenliği ve iklim değişikliğiyle mücadelede de önemli bir faktördür. Enerji verimliliğini artırmak için çeşitli ülkeler tarafından yürürlüğe konmuş yasal düzenlemeler ve standartlar bulunmaktadır. Birçok organizasyon, enerji verimliliği hedeflerini sürdürülebilirlik stratejilerinin bir parçası olarak belirler.

Tüm enerji kaynakları içerisinde elektrik enerjisi temel taş konumundadır. Bu nedenle elektriğin verimli kullanılması son derece önemlidir. Elektrik bir ülkenin gelişimini etkileyen en önemli unsurlardan biridir. Elektriğin kesintisiz güvenli bir şekilde

kullanıcıya ulaştırılması gerekir. Doğal kaynakların hızla tükenmesiyle birlikte elektrik enerjisinin her alanda verimli kullanılması gerekmektedir (Meral vd., 2009).

Şekil 3.10'da verilen Türkiye Ulusal Enerji Planı senaryosuna göre ilerleyen yıllarda kurulu gücün yenilenebilir enerji kaynaklarından daha fazla oranda sağlanması hedeflenmiştir. Bu durumda yönetim ve devlet boyutunda enerji verimliliğine verilen önemi göstermektedir.



Şekil 3.10. 2020-2035 Yılı Kaynaklara Göre Kurulu Güç Hedefleri (ETKB 3, 2023)

3.10. Enerji Yönetimi

Enerji ve yönetim kelimeleri son zamanlarda sıkça duyulan kavramlar arasındadır. Enerjiye olan ihtiyacın gün geçtikçe artması enerjinin yönetilmesi gerektiğini ortaya çıkarmıştır. Böylece enerji yönetimi adı verilen bir sistem ortaya çıkmıştır. Enerjiyi verimli kullanmak, tasarruf sağlamak enerji yönetiminin temel unsurlarıdır. Enerji yönetimi sadece belirli bir alanda faaliyet gösteren firmalar için değil, her alanda önem verilmesi gereken bir yaklaşımdır (Özbakır P., 2006)

Enerji yönetimi, enerji kaynaklarının verimli ve etkin bir şekilde kullanılmasını sağlamak için uygulanan strateji ve uygulamalar bütünüdür. Enerji yönetimi, enerji tüketimini, maliyetlerini ve çevresel etkilerini optimize etmeyi amaçlayan disiplinler arası bir alandır. Enerji yönetimiyle enerji verimliliğini artırmak, enerji maliyetlerini düşürmek, enerji

tedarik güvenliğini sağlamak ve çevresel sürdürülebilirliği desteklemek amaçlanmaktadır.

Kentleşme oranının gün geçtikçe artmasıyla birlikte artış gösteren bina sayılarından dolayı elektrik tüketimi de artış göstermektedir. Azalan fosil yakıtlar, ekonomik unsurlar, nüfus artışı gibi unsurlardan dolayı enerji tüketimine dikkat edilmesi, enerjinin doğru planlamalarla yönetilmesi gerekmektedir (Hasanona, 2021).

Enerji yönetiminin temelini doğru politikalar ve planlamalar oluşturur. Enerji tüketiminin azaltılmasına yönelik stratejiler ve teknolojiler geliştirilir. Enerji tüketimini izlemek ve analiz etmek için sistemler ve araçlar kullanılır. Ülkemiz enerji kaynakları konusunda büyük oranda dışa bağlı durumdadır. Enerjinin büyük bir kısmı dışarıdan ithal edilmektedir. Enerjinin etkin kullanımı için 2007 yılında 5627 sayılı Enerji Verimliliği Kanunu çıkarılmıştır (Aydın, 2019).

Enerji verimliliği kanunuyla enerji verimliliğini artırmak, enerji tüketimini azaltmak ve enerji kaynaklarının etkin kullanımını sağlamak amaçlanmıştır. Sanayi tesisleri, kamu binaları, ulaştırma sektörü, ticarethaneler ve enerji üretimi gibi enerji tüketiminin yüksek olduğu alanlar bu kanunun kapsamına girer. Kanunun ana hükmü şunlardır:

1. **Enerji Yönetimi:** Büyük enerji tüketicilerinin enerji yöneticisi atamalarını ve enerji yönetim sistemlerini kurmalarını zorunlu kılar.
2. **Enerji Denetimi:** Belirli büyüklükteki işletmelerin düzenli enerji denetimleri yaptırmalarını gerektirir.
3. **Binalarda Enerji Verimliliği:** Yeni binaların belirli enerji verimliliği standartlarına uygun olarak inşa edilmesini ve mevcut binaların enerji verimliliği yönünden iyileştirilmesini hedefler.
4. **Enerji Verimliliği Yatırımları:** Enerji verimliliği projelerinin teşvik edilmesi ve desteklenmesi.

5627 sayılı Enerji Verimliliği kanununun çıkarılmasıyla birlikte bu kanuna dayanan çeşitli genelge ve yönetmelikler farklı Bakanlıklar ve Cumhurbaşkanlığınca çıkarılmıştır. Cumhurbaşkanlığı'nın 2019/18 sayılı "Kamu Binalarında Enerji Tasarrufu" konulu Genelgesi doğrultusunda, 10.000m² kapalı alana sahip yada yıllık 250 TEP üzeri enerji

tüketen kamu binalarında 2023 yılı sonuna kadar en az %15 enerji tasarrufu sağlanması hedeflenmiştir. Daha sonra ise bu genelge 2023/15 sayılı genelge ile güncellenmiş ve %15 olarak belirlenen tasarruf hedefi, 2030 yılına kadar asgari %30 olacak şekilde güncellenmiştir (ETKB 4, 2023).

3.11. Okullarda Enerji Verimliliği ve Yönetimi

Ülkemizde çıkarılan Enerji verimliliği kanunuyla birlikte enerjinin etkin kullanılması ve tasarruf yapılması hedeflenmektedir. Ülkemizde enerji tüketiminin artış göstermesiyle birlikte enerji tüketiminin azaltılması ve enerji yönetimi bilincinin oluşturulması sadece özel sektörde değil resmi kurumlarda da amaçlanmaktadır (Aydın, 2019). Enerji verimliliğini etkin kullanan ülkelerin sosyal ve ekonomik anlamda gelişimlerini görmek mümkündür. Sadece üretim, imalat, ulaşım vb. sektörler değil kamu binalarında da enerjinin verimli kullanılması gerekmektedir. Kamu binaları içerisinde de okul binaları enerji tüketimi noktasında önemli bir yer tutmaktadır. Okullarda enerji yönetimi yaklaşımı oturtulması sadece tüketimin düşmesi noktasında değil, öğrencilerde de enerji bilinci oluşturulması noktasında önemlidir (Moazzen vd., 2019). Enerji verimliliği kanunu kapsamında okullarda enerjinin etkin kullanımı için çalışmalar yapılmakta, enerji yöneticisi görevlendirilmekte ve 2023 hedefleri doğrultusunda eylem planları oluşturulmaktadır (Üremiş vd., 2013).

Kamu binaları içerisinde yer alan okullar sayı olarak fazla orana sahiptir. Bu nedenle okullarda enerji verimliliği etkin olarak uygulanmalıdır. Milli Eğitim Bakanlığınca çıkarılan genelge ve yönetmelik gereği İl Milli Eğitim Müdürlükleri bünyesinde Enerji Yönetim Birimleri kurulmuştur. Kurulan bu birimlerde Enerji Yöneticisi görevlendirilmiştir. Enerji Yönetim Birimleri okullarda yapılan enerji tüketimlerini takip etmekte ve gerekli önemleri almaktadır. Okullarda enerjinin etkin kullanılması ve israfın önüne geçilebilmesi için çalışmalar yapılmaktadır. Enerji verimliliği kapsamında elektrik tüketimi okullarda ele alınması gereken konuların başında gelmektedir. Öğrenci, öğretmen, idari personel, teknik personel, yardımcı hizmetler sınıfı olarak düşünüldüğünde yaklaşık 20 milyon insanın istihdam edildiği okullarda yapılacak enerji verimliliği çalışmaları tüm ülkeye örnek olması açısından büyük önem arz etmektedir. Okullarda uygulanacak her enerji verimli davranış öğrencilerin gelecekte alışkanlık

haline getireceđi olumlu bir harekete dönüşecektir. Sadece tüketim düşmeyecek çevre bilinci de gelişecektir.

3.12. Okullarda Elektrik Tüketimi

Okullarda tüketilen enerji kaynaklarından biri elektriktir. Enerji verimliliđi kapsamında elektrik tüketiminin üzerinde durulması gerekmektedir. Sayı olarak düşünöldüğünde kamu kurumları içerisinde okulların sayısı oldukça fazladır. Tasarruf açısından bakıldığında en önemli enerji kaynaklarından biri de elektriktir. Yapılan elektrik tüketimlerinin bir noktadan izlenmesi, yönetilmesi ve gerektiğinde müdahale edilmesi gerekmektedir. Bu amaçla İl Milli Eğitim Müdürlüklerinde Enerji Yönetim Birimleri kurulmuştur. Geleceđe yönelik tasarruf hedefleri doğrultusunda geçmişte yapılan elektrik tüketimlerinden yola çıkılarak gelecekteki elektrik tüketimini tahmin edebilmek Yapay zeka teknolojisi ile mümkündür. Bu tahminler sayesinde tasarruf hedeflerine ne kadar yakın veya uzak olunduđu tespit edilerek önceden gerekli önlemler alınabilir. Elektrik tüketiminin doğru bir şekilde tahmin edilmesi, okulların enerji verimliliđini artırmalarına ve enerji tasarrufu sağlamalarına yardımcı olabilir. Tahminler, enerji kullanımının zaman içindeki değışikliklerini anlamayı ve optimize etmeyi mümkün kılar. Elektrik tüketimi tahminleri, okul yöneticilerine ve enerji yöneticilerine veri odaklı kararlar almak ve stratejik planlamalar yapmak için temel bilgiler sağlar. Ayrıca elektrik tüketimi tahminleri, okul topluluđuna enerji kullanımı ve tasarrufu konusunda eğitim sağlayabilir. Bu, öğrencilere, öğretmenlere ve diđer personele enerji bilincini artırma ve sürdürülebilir alışkanlıklar geliştirme fırsatı sunabilir

3.13. Okullarda Elektrik Tüketimini Etkileyen Faktörler

Okullarda elektrik tüketimini etkileyen çeşitli faktörler vardır. Bu faktörler, okulun fiziksel özellikleri, kullanım alışkanlıkları, teknolojik donanım ve çevresel koşullar gibi geniş bir yelpazede değışkenlik gösterir. Bu faktörlerin bazıları aşağıda verildiđi gibi sıralanabilir:

1. Büyük veya çok katlı binalar daha fazla enerji tüketir.
2. Yetersiz yalıtım, ısıtma ve soğutma için daha fazla enerji tüketimine neden olur.

3. Enerji verimliliği düşük pencereler ve kapılar, ısı kaybına yol açar. Dolayısıyla ısıtma için daha fazla elektrik harcanır.
4. Enerji verimli LED aydınlatmalar, floresan veya akkor lambalara göre daha az enerji tüketir.
5. Gereksiz yanan ışıklar, enerji tüketimini artırır.
6. Enerji tasarruflu cihazlar daha az elektrik tüketir.
7. Okulun açık olduğu saatler ve etkinlikler enerji tüketimini etkiler.
8. Öğretmen ve öğrencilerin enerji kullanım alışkanlıkları önemli bir faktördür.
9. Derslik sayıları, okulda yer alan öğrenci ve öğretmen sayıları tüketimi doğrudan etkiler.

Okullarda elektrik tüketimini etkileyen faktörler, çok çeşitli ve karmaşıktır. Enerji verimliliği, sürdürülebilirlik ve maliyet tasarrufu için bu faktörlerin dikkate alınması önemlidir.

3.14. Yapay Zeka

Günümüzde en çok merak uyandıran kavramlardan biri yapay zekadır. İlk defa 1956 yılında ortaya atılan yapay zeka kavramı günümüze kadar üzerine koyarak gelişim göstermiştir. Yapay zekânın birçok tanımı mevcuttur. Genel bir tanım yapmak gerekirse yapay zeka bir bilgisayarın ya da bilgisayar sistemiyle desteklenen bir makinenin insan davranışları sergilemesi, insan gibi çözümlemeler üretebilmesi yeteneğidir (Öztürk ve Şahin, 2018). Günümüzde hemen hemen herkesin yapay zekayla ilgili bir fikri bulunmaktadır. Konuya uzak olan bir kişiye bile yapay zekâ denildiğinde aklına insansı davranışlar gösteren robotların gelmesi muhtemeldir. Aslında yapay zekayı anlamadan önce insan beyninin çalışma şeklini anlamak gerekmektedir. Günümüzde hala insan beyninin çalışması tam olarak açıklanamamışken, insanı taklit etmeye çalışan yapay zekayı anlamaya çalışmak kolay olmayacaktır. İnsan beyni içinde sayısız sır barındırır. Beynin çalışma sistemi tam olarak açıklandığında yapay zekanın gelişimi de ileri noktalara ulaşacaktır (Arslan, 2020).

Yapay zeka çok disiplinli bir yapıdır. İçerisinde bilgisayar mühendisliği, yazılım, elektronik, felsefe gibi farklı bilimlere bulundurulur. Yapay zekâ makinelerin insan

zekasının bazı yönlerini taklit etme yeteneğini ifade eder. Yapay zekanın temel amacı öğrenme, algılama, problem çözme ve karar verme gibi insan zekasına özgü işlevleri gerçekleştirebilen sistemler oluşturmaktır (Russel ve Norvig, 2010). Makine öğrenmesi, yapay zekanın merkezi unsurlarından biridir. Makine öğrenmesi, verilerden öğrenme ve bu öğrenilen bilgileri yeni durumlara uygulama yeteneği olarak ifade edilir (Alpaydın, 2020). Görüntü ve ses tanıma, yapay zekanın önemli yönlerindendir. Yapay zekâ sistemleri, kameralar ve mikrofonlar aracılığıyla elde edilen verileri işleyebilir (Murphy, 2012). Karar destek sistemleri, yapay zekanın önemli bir uygulama alanıdır. Bu sistemler, verilere dayalı karar verme süreçlerinde insanları destekler (Kumar, 2012).

Yapay zekanın toplumsal ve ekonomik etkileri geniştir. Etik ve güvenlik sorunları, yapay zekanın kararları, gizlilik ve güvenlik ile ilgili endişeleri beraberinde getirir (Bostrom, 2014). Günümüzde teknoloji ve bilim dünyasının önde gelenleri yapay zekayla ilgili çekincelerini dile getirip, yapay zekanın olumsuz yönlerine dikkat çekmektedirler. Yapay zekâ insanlığın yerini alabilir mi, ölümcül bir silah olabilir mi gibi negatif yorumlar olmasına rağmen yapay zekânın hayatımızı kolaylaştıran bir sürü örneği vardır. Hepimizin kullandığı arama motorları, insansız tarım, insansız ulaşım, otomatik şehir planlaması bu örneklerden bir kaçıdır (Köroğlu, 2017). Yapay zekâ sayesinde insanlar için tehlikeli ve zahmetli işler kolaylıkla yapılır, binlerce veri kolay bir şekilde analiz edilir ve karar verme süreçleri hızlandırılır. Yapay zekâ doğru kullanıldığında tekrarlayan ve yorucu işleri otomatik olarak yerine getirilebilir, öngörülemeyen durumlar ve potansiyel riskler engellenebilir, daha hızlı ve verimli çalışma ortamıyla birlikte daha doğru kararlar verilebilir.

3.15. Yapay Zekanın Kullanım Alanları

Yapay zeka bir çok disiplin tarafından sahiplenilir. Bulanık mantık, uzman sistemler, genetik algoritmalar ve yapay sinir ağları yapay zekayla yakından ilgilidir (Pirim, 2006). Yapay Zekâ modern dünyada çok sayıda alanda kullanılmaktadır ve bu kullanım alanları hızla genişlemektedir. Yapay zekanın bazı önemli kullanım alanları şunlardır:

3.15.1. Sağlık sektörü

Günümüzde kronik hastalıkların artış göstermesi, insan yaşının uzaması sonucu evde bakım hizmetlerine olan ihtiyacın artması, pandemi gibi salgın hastalıkların olması sağlık hizmetlerinde değişime sebebiyet vermiştir. Bilgi teknolojilerinin kullanımı gereklilik haline gelmiştir. İş yükünün artması, yeteri kadar çalışan personel olmaması yapay zeka uygulamalarının kullanılmasına yol açmıştır (Akalin ve Veranyurt, 2021).

Sağlık alanında yapay zeka uygulamaları ile tıbbi görüntüler analiz edilerek hastalıkların teşhisi konulup tedavi yolları belirlenir. Çok sayıda biyolojik verinin analizi yapılarak yeni ilaçlar üretilebilir. Hastaların genetik bilgilerinden yola çıkılarak kişiye özel tedavi yöntemi geliştirilebilir.

3.15.2. Finans ve bankacılık

İşletmelerin veri tabanlarında çok fazla sayıda veri bulunmaktadır. Basit istatistiksel yöntemler bu verileri analiz etmek için yetersiz kalmışlardır. Bu verilerin analiz edilip anlamlı sonuçlara ulaşabilmek için yapay zekâ uygulamalarına ihtiyaç olmuştur. Finans alanıyla yapay zekânın kesişimi sonucu finansal teknolojinin kısaltması olan FinTek kavramı ortaya çıkmıştır (Yıldız, 2022).

Yapay zeka uygulamaları ile piyasa verileri analiz edilip ticaret kararları otomatik olarak alınabilir. Müşterilerin kredi riski değerlendirilebilir. Müşterilerle konuşmayı simüle etmek için chatbot adı verilen yazılımlar geliştirilebilir.

3.15.3. Perakende ve e-ticaret

Yapay zekanın kullanılmaya başlamasıyla e-ticaret dünyasında bir dönüşüm başlamıştır. Yapay zeka ticaretle uğraşan işletmelere yol gösterici olmuştur. Ticarete küresel çapta ses getirebilmek için yapay zekanın işletme uygulamalarına entegre edilmesi bir gereklilik haline gelmiştir. Yapay zekayla ticaret uygulamalarına hız ve verimlilik gelmiştir (Güven ve Güven, 2023).

Yapay zeka uygulamaları ile müşterilerin geçmiş alışverişleri incelenip analizler yapılarak kişisel ürün önerileri yapılabilir. Satılan ürünler analiz edilerek talep tahminleri yapıp fiyatlar üzerinde güncellemeler yapılabilir.

3.15.4. Otomotiv ve ulaşım

Yapay zekânın otomotiv endüstrisinde etkisi yüksektir. İnsan etkeni nedeniyle her yıl çok sayıda gerçekleşen trafik kazalarını sürücüsüz araç teknolojisiyle azaltmak mümkündür. Sürücüsüz araçlar ile yakıttan tasarruf yapmak da mümkündür. Araba sahibi olup riskler nedeniyle aracını sürmekten çekinen çok sayıda kullanıcının olduğu da bilinmektedir (Soegoto vd., 2019).

Yapay zeka ile kendi kendine sürüş yapabilen araçlar üretilmekte, trafik analizi yapılmakta ve yol güvenliği artırılmaktadır. Trafik akışı analiz edilerek sürücüler trafik sıkışıklığı olmayan yollara yönlendirilmektedir.

3.15.5. Üretim ve endüstri

Fabrikalarda üretim, planlama ve kontrol aşamalarında yapay zeka uygulamalarından faydalanılarak verimlilik artırılmaktadır. Artık geleneksek sistemler yetersiz kalmakta ve modern uygulamalara ihtiyaç duyulmaktadır. İşletmeler piyasada kalıcı olabilmek ve daha da ileri gidebilmek için yapay zeka teknolojilerine yatırım yapmaktadırlar (Ever ve Demircioğlu, 2019).

İşletmelerdeki ekipmanların arızaları yapay zeka uygulamaları ile önceden tahmin edilip planlı bakım onarım süreçleri geliştirilir. Üretim süreçleri otomatize edilerek verimlilik artırılır.

3.15.6. Eğitim ve araştırma

Günümüzde yapay zeka eğitim kurumları tarafından farklı şekillerde yaygın olarak benimsenip kullanılmaktadır. İnsansı robotların ve web tabanlı chatbotların sayesinde eğitmenler olmadan eğitim verilmektedir. Öğrenci ödevlerinin gözden geçirilmesi ve

notlandırılması da yapay zeka uygulamaları sayesinde yapılabilmektedir (Chen vd., 2020).

Yapay zeka uygulamalarıyla öğrencilerin öğrenme stilleri analiz edilip kişiselleştirilmiş eğitim materyalleri hazırlanabilir, büyük veri setleri analiz edilerek akademik araştırmalarda yeni keşifler yapılabilir.

3.15.7. Medya ve eğlence

Günümüzde insanların sık sık kullandığı sosyal medya uygulamaları yapay zeka teknolojilerini kullanarak kullanıcılara en güncel bilgiyi vermeye çalışır. Medya veri tabanlarında çok fazla veri bulunur. Bu veriler kullanılarak kullanıcıya hızlı ve etkili çıktılar sunulur (Özçağlayan ve Kortak, 2023). Bilgisayarda yapılan en sık işlemlerden biri de oyun oynamaktır. Zaman ilerledikçe kullanıcıların oyunlardan beklentisi de giderek artmaktadır. Oyunlar geliştirilirken yapay zekanın kullanılmasıyla birlikte oyuncuların ihtiyaçlarına cevap verilmektedir. Özellikle çoklu oyunlarda bilgisayar tarafından yönetilen oyun karakterleri yapay zeka sayesinde gerçek bir oyuncu gibi hareket etmektedir (Gür vd., 2018).

Yapay zeka uygulamaları ile kullanıcıların izledikleri ya da görüntüledikleri haber içeriklerine göre kişiselleştirilmiş öneriler sunulur. Bilgisayar oyunları daha gerçekçi ve zorlayıcı olarak kullanıcılara sunulur.

3.15.8. Güvenlik ve gözetim

Kurum ve şirketler sistemlerine yapay zekayı entegre ederek olağan dışı durumları hızlıca tespit edip çözümlemektedirler. Kendi kendine öğrenen sistemler sayesinde olası riskler karşısında güvenlik ve savunma hizmetleri aktif hale getirilir (İrdem ve Çobanoğlu, 2021).

Yapay zekâ uygulamalarıyla kamu güvenliği ve kişisel güvenlik sağlanır. Ağ güvenliği izlenerek tehditlere otomatik olarak tespit edilir.

Yapay zekâ, bu alanların her birinde, iş süreçlerini otomatize etmek, verimliliği artırmak, yeni keşifler yapmak ve daha iyi kararlar almak için kullanılmaktadır. Teknolojinin ilerlemesiyle birlikte, yapay zekanın kullanım alanları sürekli olarak genişlemekte ve çeşitlenmektedir.

3.16. Yapay Zeka Kullanılarak Elektrik Tüketiminin Tahmin Edilmesi

Ülkelerin kalkınmalarının temel araçlarından biri olan elektrik enerjisine olan ihtiyaç insanların yaşam standartlarının artmasıyla birlikte daha da artmıştır. Elektrik depolanamadığından ihtiyaç duyulan elektriğin temin edilebilmesi için gelecekte ne kadar elektrik enerjisine ihtiyaç duyulduğu önceden belirlenmelidir (Yıldız, 2021). Yapay zekâ kullanılarak elektrik tüketiminin tahmin edilmesi, enerji sektöründe giderek daha fazla önem kazanan bir uygulama alanıdır. Bu yaklaşım, enerji tüketiminin daha etkin yönetilmesine, enerji verimliliğinin artırılmasına ve enerji tedarik planlamasının iyileştirilmesine yardımcı olur. İşte bu konuda dikkate alınması gereken bazı önemli noktalar vardır. Elektrik tüketimini tahmin etmek, enerji talebinin daha verimli bir şekilde karşılanmasını sağlar. Tüketim desenlerinin anlaşılması, enerji verimliliği stratejilerinin geliştirilmesine yardımcı olur. Gelecekteki enerji ihtiyaçlarını tahmin etmek, altyapı yatırımlarının daha etkili planlanmasını sağlar. Elektrik tüketiminin geçmiş verilerini analiz ederek gelecekteki tüketim desenlerini tahmin eder. Lineer ve lojistik regresyon gibi yöntemler, tüketim verilerini ve etkileyen faktörleri analiz eder. Sinir ağları ve LSTM (Long Short-Term Memory) gibi derin öğrenme modelleri, karmaşık tüketim desenlerini tahmin etmede etkili olabilir.

Binaların ve evlerin enerji tüketimlerini, büyük enerji tüketicileri olan endüstriyel tesislerin tüketimlerini tahmin etmek mümkündür. Önceki yılların elektrik tüketim verileriyle birlikte elektrik tüketim tahmini yapılacak ortama ait gerekli veriler kullanılarak algoritmalar geliştirilip tahminde bulunulabilir. Ancak yüksek kaliteli ve kapsamlı verilere erişim bazen zor olabilir. Farklı veri setleri ve durumlar için doğru modelin seçimi ve hiperparametre ayarları önemlidir.

Yapay zekâ ve makine öğrenmesi yöntemlerinin enerji tüketimi tahminindeki kullanımı, hem bireysel tüketicilere hem de enerji şirketlerine büyük faydalar sağlayabilir. Bu

teknolojiler, daha sürdürülebilir ve verimli enerji sistemlerinin geliştirilmesinde kritik bir rol oynayabilir (Kamber vd., 2021)

3.17. Makine Öğrenimi

Makine öğrenimi bir yapay zekâ tekniğidir. İnsan beynini taklit etmeye çalışır. Nasıl ki İnsanlar doğrularını artırabilmek için tecrübe edinmeye çalışıyorlarsa makine öğrenimi de doğruluğunu yeni deneyimlerle artırabilir. Makine öğreniminin gerçekleşebilmesi için sisteme bir veri seti verilir, algoritmalarla sistem eğitilir ve tahmin yapılmaya çalışılır. Yapılan her tahminle sistemin deneyim kazanması sağlanır ve doğruya ulaşılmaya çalışılır. Sonuç olarak çeşitli sınıflama, kümeleme veya tahminleme işlemleri yapılır (Gezmez, 2022). Çok sayıda verinin incelenerek analiz edilmesi zordur. Buradaki amaç verileri kullanarak tahminde bulunmaktır. Makine öğrenmesi yöntemleri bu amaçla geliştirilmiştir. Verilerin incelenip içerisinden anlamlı verilerin çıkarılması da veri madenciliği olarak adlandırılır (Diri, 2014). Makine öğrenmesi sayesinde bir sisteme insan gibi öğrenebilme yeteneği kazandırılmaya çalışılır. Öğrenebilme için sisteme verilen veriler arasından bir örüntü çıkarılır, veriler arasında ilişkiler incelenir ve bir çıkarım elde edilir. Örneğin borsadaki bir hisse senedinin geçmiş dönemdeki inişli çıkışlı hareketleri incelenerek gelecek için tahminde bulunulabilir. Makine öğrenimi sayesinde makineler yada bilgisayar sistemleri birbirinden zor görevleri başarıyla yerine getirir (Keleş vd., 2020). Makine öğrenmesi yöntemleri üç gruba ayrılır. Bunlar öğreticili, öğreticisiz ve yarı öğreticili öğrenme yöntemleridir. Öğreticili yöntemler gözetimli ya da denetimli öğrenme, öğreticisiz yöntemler gözetimsiz ya da denetimsiz öğrenme ve yarı öğreticili yöntemler ise yarı gözetimli öğrenme ya da yarı denetimli öğrenme olarak adlandırılabilirler (Onan ve Korukoğlu, 2016). Öğrenme türleri ve algoritmalar aşağıdaki şekilde açıklanabilir:

3.17.1. Gözetimli öğrenme (denetimli öğrenme)

Denetimli öğrenmede modelin öğrenebilmesi için etiketli veri setine ihtiyaç duyulur. Öncesinde hangi bilginin hangi veriye karşılık geldiği bellidir. Girdilerle çıktılar arasındaki ilişkiler tespit edilip en uygun fonksiyon geliştirilir. Böylece sisteme girilen yeni bir girdinin hangi çıktıyı vereceği tahmin edilir (Aydın ve Özkul, 2015) . Örneğin

demontaj şekilde alınan bir ürün için yanında parçaların nasıl birleştirileceğine dair bir kurulum kılavuzu verilir. Denetimli öğrenmede de makineye parçalar ve kurulum kılavuzu verilip parçaların montaj edilmesi istenir.

3.17.2. Gözetimsiz öğrenme (denetimsiz öğrenme)

Denetimli öğrenmenin aksine sisteme etiketsiz veriler verilir. Bu veriler arasında var olan örüntünün makine tarafından tespit edilmesi istenir. Sistemin elinde sadece veriler bulunur. Sistemin kendi kendine öğrenmesi istenir (Keskin ve Yıldız, 2018). Alışveriş sitesinde sepete eklenen birkaç üründen sonra sitenin bazı ürün tavsiyelerinde bulunması denetimsiz öğrenmeye örnek olarak verilebilir.

3.17.3. Pekiştirmeli öğrenme

Pekiştirmeli öğrenme de sistemin öğrenebilmesi için bir seti bulunmaz. Alınan tepkilere göre makine öğrenmesini gerçekleştirir. Bir ödül sistemi geliştirilmiştir. Alınan tepkilere elde edilen ödül değerlendirilir ve öğrenme buna göre gerçekleşir (Efe, 2021). Bir bebeğin yürümeyi öğrenmesi için defalarca düşmesi ve her düşüşünden sonra deneyim kazanarak yürümeyi öğrenmesi pekiştirmeli öğrenmeye örnek olarak verilebilir.

3.17.4. Algoritmalar

Makine öğrenmesi algoritmaları denetimli ve denetimsiz olmalarına göre ayrılırlar. Doğrusal regresyon, lojistik regresyon, karar ağaçları, sinir ağı çözümleri, rasgele orman, destek vektör makineleri, k-en yakın komşular yöntemleri denetimli öğrenme algoritmalarıdır. Birliktelik analizi yapmak için kullanılan apriori ve fp-growth teknikleri, kümeleme analizleri yapmak için kullanılan k ortalamalar yöntemleri denetimsiz öğrenme algoritmalarıdır (Gezer ve Saylan, 2017)

Makine öğrenimi uygulama alanlarına çeşitli örnekler verilebilir. Büyük veri yığınlarının makine öğrenmesi yöntemleriyle işlenmesi sonucu yeni veriler oluşur. Özellikle mühendislik sektöründe yoğun olarak kullanılan makine öğrenme yöntemleri ile mimarlık alanının tasarım ve üretim aşamalarında da etkili sonuçlar alınabilir. Özellikle


tasarım aşamasında yeni fikirler üretilmesine olanak sağlayıp üretim aşamasında da risklerin azaltılması için makine öğrenmesi yöntemlerinden faydalanılır (Şapcı, 2022). Finans sektöründe borsada yer alan hisse senetlerinin ve döviz kurunun hareketleri, banka müşterilerinin kredi başvurularının değerlendirilmesi, müşteri ilişkilerinin zenginleştirilmesi ve güvenlik uygulamaları makine öğrenmesi yöntemleriyle geçmiş verilerin analizi sonucu elde edilir. Geçmiş yıllara ait hava durumu verilerinde hareket edilerek gelecek için hava durumu tahmininde bulunulur (Alpaydın, 2020). Tıp alanında sağlık hizmetlerinin geliştirilmesi, hastalıkların teşhisi, görüntü analizi, hastaların izlenmesi, halk sağlığı, gibi uygulamalarda makine öğrenmesi yöntemleri kullanılır (Hoşgör ve Güngördü, 2022). Metin madenciliği ve duygu analizi için çeşitli verilerin yer aldığı büyük veri yığınlarına ihtiyaç duyulur. Karmaşık süreçlerin işlenip sonuçlandırılması için yüksek hesaplama gücü gerekir. Bu tür uygulamalarda makine öğrenmesi yöntemleri ile etkili sonuçlar alınabilir (Atalay ve Çelik, 2017). E-ticaret uygulamaları günümüzde hızla yaygınlaşmaktadır. Bu sayfalardan müşterilerin aldıkları ürünlerden elde edilen işlenmemiş çok sayıda veri bulunur. Makine öğrenmesi yöntemleriyle alınan ürünlerin sınıflandırması yapılarak kategoriler ortaya çıkarılabilir. Bu platformların müşterilerini daha iyi anlayabilmeleri sağlar, müşteriler belirli gruplara ayrılır ve müşterilere özel teklifler sunulur (Ergün, 2023). Dünya genelinde enerjiye olan ihtiyaç her geçen gün artış göstermektedir. Enerji krizinin olmaması için talebin bilinmesi önemlidir. Enerji kaynaklarının planlamasının yapılabilmesi kriz oluşumunun önüne geçer. Planlama yapabilmek için de gelecekte enerji kaynaklarına olan ihtiyacın bilinmesi önemli bir avantaj oluşturur. Makine öğrenmesi yöntemleriyle geleceğe yönelik elektrik ve doğalgaz tüketimleri tahmin edilebilir (Karaman ve Bektaş, 2023).

Makine öğrenimi, verinin daha derin anlaşılması ve karar alma süreçlerinin organize edilmesi için kritik bir teknolojidir. Bu alan, sürekli olarak gelişmekte olup, hem akademik araştırmalarda hem de endüstriyel uygulamalarda önemli bir yer tutmaktadır.

3.18. Makine Öğrenmesi Algoritmaları

3.18.1. Yapay sinir ağları

Yapay sinir ağı insan beyninin biyolojik yapısını taklit etmeye çalışır. Bu yapı önceden öğrenilmiş ya da sınıflandırılmış bilgileri alarak yeni bilgiler üretir veya yeni kararlar alabilir. Kullanımı yaygın olan yapay sinir ağları örüntü tanıma, robotik, sinyal işleme gibi alanlarda başarılı bir şekilde kullanılır (Öztürk ve Şahin, 2018). İnsan beyni nasıl ki öğrenme, genelleme, hatırlama işlemlerini yapabiliyorsa yapay sinir ağı da insan beyninin bu özelliklerini gerçekleştirmeye çalışır. Yapay sinir ağı öğrenmeye çalışırken kullanılan algoritmaların özünü matematiksel formüller oluşturur (Kabalcı, 2014). YSA sadece sayısal verilerle çalışabildiğinden kullanılan veri seti içerisinde nominal veriler varsa bunları sayısal verilere çevrilmesi gerekir (Ağyar, 2015). Bir yapay sinir ağının görevi kendisine verilen girdilerden bir çıktı elde etmektir. Bunun için ağ bazı örneklerle eğitilir. Daha sonra öğrenme gerçekleşir ve genelleme yapıp karar verecek seviyeye gelinir. Son olarak bu kazanımlardan bir çıktı alınır.




Şekil 3.11. Biyolojik Sinir Hücresi

Şekil 3.11’de görüldüğü gibi insan beynindeki sinir hücreleri birbirlerine aksonlarla bağlıdır. Sinir hücreleri arasındaki veri akışı bu aksonlarla sağlanır. İnsan beynini taklit eden yapay sinir ağında da çok sayıda yinelenebilir elemanlar birbirilerine paralel olarak bağlanmıştır. YSA sahip olduğu özelliklerden ötürü birçok yönteme göre daha sağlıklı

sonuçlar verir. Öğrenilebilirlik daha yüksek ise hata toleransı daha düşüktür. İlk çalışmalarının 1943 yılında başladığı YSA gelişimini sürekli devam ettirerek günümüzde yaygın şekilde kullanılmakta ve başarılı makine öğrenme yöntemlerinden biri olarak duyulmaktadır (Şen, 2004). YSA incelediğinde birbirine paralel olarak bağlı olan basit işlem elemanlarına nöron denir. Nöronlar arasındaki bağlantıların ağırlıkları vardır. Komşu nöronlar arasında bulunan bu ağırlıklar ilişkinin kuvvetini temsil ederler. YSA eğitilirken elde edilen öğrenme verileri nöronların arasındaki ağırlıklara göre elde edilen yeni ağıın üzerinde saklanır (Erbaş, 2005).

Şekil 3.12’de basit bir yapay sinir ağı yapısı görülmektedir. Yapay sinir ağının sinir hücresi vardır. Her bir sinir hücresi Şekil 2’de görüldüğü gibi 5 kısımdan oluşmaktadır. Girişler X ile gösterilmekte olup çok sayıda olabilirler. Bu girişler dış dünyadan da olabilir, başka bir hücreden almış olduğu bilgiyi sinire de getirebilir. Girişlerin her biri bir ağırlıkla çarpılır ve sonrasında toplama fonksiyonu ile tüm çarpımlar toplanırlar. Burada yer alan W ağırlıkları farklı değerler alırlar ve aldıkları değere göre gelen bilginin önemini gösterirler. Sonuç oluşturmak için aktivasyon fonksiyonu ile işlem yapılır. Girdilere karşılık hücrenin üreteceği değer burada belli olur. Son olarak sonuç diğer sinirlere veya dış dünyaya çıktı olarak yolları (Akanesen, 2023).



Şekil 3.12. Basit Yapay Sinir Ağı Yapısı (Keskenler ve Keskenler, 2017)

Tablo 3.1. Biyolojik ve Yapay Sinir Ağı'nın Karşılaştırılması

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm(İşlem Elemanı)
Sinaps	Ağırlık
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıkış


Yapay sinir ağları yüz tanıma, nesne tanıma, çeviri, duygu analizi, metin üretimi, hava durumu tahmini, hisse senedi fiyat tahmini, karmaşık strateji oyunu gibi uygulamalarda kullanılabilir. Öğrenme sürecinde ağ, verilen eğitim veri seti üzerinden belirli bir hedefe ulaşana kadar eğitilir. Modelin genelleştirme kabiliyetini test etmek için doğrulama veri seti kullanılır. Modelin gerçek dünya verileri üzerindeki performansını değerlendirmek için test veri seti kullanılır. Yapay sinir ağlarında dikkat edilmesi gereken bazı durumlar vardır. Model, eğitim verilerine aşırı uyum sağlarsa genelleştirme yapamaz duruma gelir. Buna aşırı öğrenme denir. Karar verme süreçleri dışarıdan kolayca anlaşılmayabilir. Büyük ve karmaşık ağlar, önemli miktarda hesaplama gücü gerektirebilir. Yapay sinir ağları, son yıllarda AI ve makine öğrenmesi alanlarında büyük ilerlemelere yol açmıştır ve sürekli olarak gelişmekte olan bir alandır. Bu teknoloji, karmaşık desenleri ve verileri işleyebilme kabiliyetiyle birçok farklı uygulama alanında devrim yaratabilir.

3.18.2. Yapay sinir ağı modelleri

Yapay sinir ağlarında öğrenme denetimli (gözetimli) ve denetimsiz (gözetimsiz) olmak üzere iki şekilde yapılır. Denetimli öğrenmede sisteme hem giriş hem de çıkış değerleri verilir. Sistem giriş ve çıkış değerleri arasındaki ilişkiyi kurup öğrenme işlemini gerçekleştirir. Bağlantılar arasındaki ağırlıklar ağ tarafından rastgele ayarlanır. Denetimsiz öğrenme de ise sisteme sadece giriş değerleri verilir ve sistemin bir çıkış değeri elde etmesi istenir. Ağ giriş değerlerini kendi aralarında sınıflayarak bir model oluşturur (Öztemel, 2003). Yapay sinir ağları tek katmanlı ve çok katmanlı olmak üzere iki sinir ağı modeline sahiptir.

3.18.2.1. Tek katmanlı yapay sinir ağı

Tek katmanlı yapay sinir ağı Şekil 3.13’de görüldüğü gibi sadece girdi ve çıktı katmanından oluşurlar. Doğrusal olmayan problemlerde tercih edilmezler. Birden çok girdi değeri olabilir.




Şekil 3.13. Tek Katmanlı Yapay Sinir Ağı Modeli

Bu modelde, giriş katmanındaki her bir nöron doğrudan çıktı katmanındaki nöronlara bağlanır. Giriş katmanı, verinin her bir özelliğini bir nöronla temsil eden düğümlerden oluşur. Çıktı katmanı giriş katmanındaki veriler üzerinde işlem yaparak sonuç üreten nöronlardan oluşur. Tek katmanlı ağlarda, genellikle tek bir çıktı nöronu bulunur. Her giriş nöronu, çıktı nöronuna bağlanırken belirli ağırlıklar ile çarpılır. Çıktı nöronunda, tüm girdi değerleri ağırlıklarıyla çarpılır ve toplanır. Toplam girdi, bir aktivasyon fonksiyonundan geçirilir. Bu, genellikle basit bir lineer aktivasyon veya basamak fonksiyonu olabilir. Aktivasyon fonksiyonunun çıktısı, ağın nihai çıktısı olarak kabul edilir (Ersoy ve Kartal, 2012). Tek katmanlı sinir ağı, basit desen tanıma ve veri sınıflandırma görevlerinde kullanılabilir. Tek katmanlı ağlar, daha karmaşık problemleri çözmek için yetersizdir.

3.18.2.2. Çok katmanlı yapay sinir ağı

Çok katmanlı yapay sinir ağı Şekil 3.14’de görüldüğü gibi girdi katmanından, gizli katmanlardan ve çıktı katmanından oluşur. Karmaşık problemlerin çözümünde kullanılabilirler. Dolayısıyla doğrusal olmayan problemlerin çözümünde de tercih edilebilirler. Girdi katmanında çok sayıda giriş olabilir. Problemin türüne göre birden

fazla gizli katman ve her bir gizli katmanda çeşitli sayıda düğüm olabilir. Gizli katmandaki veriler çeşitli fonksiyonlarla işlenip çıkış katmanına aktarılır.



Şekil 3.14. Çok Katmanlı Yapay Sinir Ağı Modeli

Veri, giriş katmanından başlayarak ağıın her katmanından sırasıyla geçer. Her katmandaki nöronlar, önceki katmandan gelen girdilere göre aktivasyon fonksiyonuyla hesaplanır. Her nöronun çıktısı, aktivasyon fonksiyonları (örneğin ReLU, sigmoid, tanh) kullanılarak hesaplanır. Bu fonksiyonlar, ağıın doğrusal olmayan problemleri çözme yeteneğini sağlar. Her bağlantının gücünü temsil eden ağırlıklar ve her nöron için eklenen biaslar(nöronun çıktısına eklenen sabit değer), modelin eğitimi sırasında ayarlanır (Ataseven, 2013).

Eğitim sürecinde modelin çıktısı ile beklenen sonuç arasındaki hata, geri yayılım algoritması kullanılarak hesaplanır ve ağırlıklar bu hata oranına göre güncellenir. Stokastik Gradyan İnişi (SGD), Adam ve RMSprop gibi optimizasyon algoritmaları, ağırlıkların etkili bir şekilde güncellenmesini sağlar (Yılmazel vd., 2018). Model, eğitim verilerine aşırı uyum sağladığında ve yeni verilere iyi genelleme yapamadığında ortaya çıkar. Çok katmanlı yapay sinir ağlarının karar verme süreçleri, genellikle karmaşık ve "kara kutu" niteliğindedir. Bu tür modeller, genellikle yüksek hesaplama gücü ve veri


miktarı gerektirir. Çok katmanlı yapay sinir ağıları, modern yapay zeka ve makine öğrenimi uygulamalarının çoğunda temel rol oynar ve karmaşık problemleri çözme yetenekleriyle önemli başarılar elde etmiştir.

3.18.3. Çok katmanlı algılayıcı (multi-layer perceptron) yöntemi

Günlük hayatta karşılaşılan problemlerin çoğunun doğrusal yapıda olmaması sonucu yapay sinir ağılarıyla yapılan çalışmaların durma noktasına gelmesine sebep olmuştur. Bunun üzerine bazı bilim insanları yapay sinir ağlarının doğrusal olmayan problemlerde kullanılabilmesi için çalışmalar yapmışlardır. Doğrusal olmayan XOR problemlerinin çözümü için Çok Katmanlı Algılayıcı tekniğini geliştirmişlerdir. MLP tekniği yapay sinir ağlarına olan ilgiyi artırmış ve veri madenciliğinde yeni bir çığır açmıştır. Özellikle mühendislik uygulamalarında sıkça kullanılan bu modelde birçok öğretim algoritmasının ağı eğitebilmesi için kullanılabilir olması da modelin yaygınlaşmasına etki etmiştir (Demirhan, 2015).

Günümüzde sınıflandırma problemleri içerisinde en çok kullanılan yöntemlerden biri olan MLP tekniğinde öğrenme yöntemi olarak Delta tekniği adı verilen bir yöntem kullanılır. Amaç sistemden çıkan çıktı ile istenen çıktı arasındaki farkı minimuma indirmektir (Tanrıku ve Sazlı, 2009). Çok katmanlı algılayıcı da denetimli öğrenme söz konusudur. Modele bir veri seti verildiğinde bu veri seti içerisinde girdilerin karşılığında alınması gereken çıktılarda yer alır. Böylece model girdiler ve çıktılar arasında analiz yaparak öğrenme işlemini gerçekleştirir. Öğrenme işlemini gerçekleştirdikten sonra kendisine verilen yeni girdilerden çıktıları yani tahminleri üretir. Kendisine verilen her girdi için bir çıktı üretir (Çatal ve Özyılmaz, 2012).

Şekil 3.15’de üç girdili bir gizli katmanlı ve üç çıktılı birçok katmanlı algılayıcının yapısı görülmektedir. Girdi katmanı bir veya birden fazla olabilir. Aynı şekilde gizli katmanda problemin türüne göre bir veya birden fazla olabilir. Gizli katmandaki nöron sayısı kullanıcı tarafından değiştirilebilir. Diğer makine öğrenmesi yöntemlerinden farklı olarak öğrenme işlemi örnekler sayesinde sağlanır. Bu yapıda kullanılan denetimli(öğretmenli) öğrenme sayesinde ileri beslemeli-geri yayımlı algoritma kullanılabilir. Bu algoritma yönetilebilir bir metottur. (Kaya ve Kenan, 2021).



Şekil 3.15. Çok Katmanlı Algılayıcı Yapısı

Bu yapıda öğrenme veya karar verme işlemi gerçekleşirken öncelikle her bir girdi kendisine verilen ağırlıkla çarpılır. Çarpım işleminden sonra girdiler toplama fonksiyonuna göre toplanırlar. Ağın çalışma şekline göre kullanıcı tarafından bias değeri eklenir. Aktivasyon fonksiyonu ise kendisine gelen verilere göre bir sonuç yani karar üretir (Bulut, 2016)

3.18.3.1. Toplama fonksiyonunun rolü

Çok katmanlı algılayıcı içerisindeki toplama fonksiyonları, her nöronun girdilerini ve bu girdilere atanan ağırlıkları toplayarak bir sonraki işlem adımına geçilmesini sağlar. Bu fonksiyonlar, ağın her bir nöronundaki işlemlerin temelini oluşturur. Her nöron, kendisine bağlı olan önceki katmanın nöronlarından gelen girdileri alır. Her girdi, o girdiye karşılık gelen ağırlık ile çarpılır. Bu ağırlıklar, girdilerin nöronun çıktısındaki etkisini belirler. Her bir ağırlıklandırılmış girdi toplanarak nöronun toplam girdi değeri hesaplanır (Kaynar ve Taştan, 2009). Bir nöronun toplam girdi değeri genellikle Eşitlik 3.1'deki gibi hesaplanır:

$$\text{Toplam Girdi} = \sum_{i=1}^n (w_i \times x_i) + b \quad (3.1)$$

w_i : i. girdinin ağırlığı

x_i	:	i. girdinin değeri
b	:	Bias değeri (nöronun aktivasyon eşiğini ayarlar)
n	:	Toplam girdi sayısı

Örneğin bir nörona üç girdi (x_1, x_2, x_3) geliyor ve bu girdilerin ağırlıkları (w_1, w_2, w_3) var. Bu durumda, nöronun toplam girdi değeri Eşitlik 3.2’de verildiği şekilde hesaplanır:

$$\text{Toplam Girdi} = (w_1 \times x_1) + (w_2 \times x_2) + (w_3 \times x_3) + b \quad (3.2)$$

3.18.3.2. Yaygın aktivasyon fonksiyonları

MLP'lerin en önemli unsurlarından biri aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonları, bir sinir ağının gizli katmanlarındaki her düğümde uygulanır ve çıktı katmanında da kullanılabilir. Bu fonksiyonlar, ağın öğrenme yeteneğini ve karmaşık problemleri çözme kapasitesini belirler (Altun, 2022). Yaygın aktivasyon fonksiyonları aşağıdaki gibidir:

1. **ReLU (Rectified Linear Unit):** Doğrultulmuş lineer birim anlamına gelir. ReLu, negatif girdiler için sıfır değerini, pozitif girdiler için ise girdinin kendisi neyse sonucu da aynı değer olarak döndürür. Bu fonksiyon sinir ağlarında sıklıkla kullanılır. Çünkü hesaplama açısından verimlidir ve gradyan kaybı sorununu azaltmaya yardımcı olur (Çakı ve Bayram, 2022).

$$F(\text{net}) = A * \text{net} \quad (3.3)$$

2. **Sigmoid:** Sigmoid fonksiyonu, girdileri 0 ile 1 arasında bir değere dönüştürür. Süreklidir ve türevi alınabilir. Bu fonksiyon özellikle ikili sınıflandırma görevlerinde çıktı katmanında kullanışlıdır. Ancak, gradyan kaybı sorunu nedeniyle derin ağlarda daha az tercih edilir (Çelik, 2022). Örneğin, sigmoid fonksiyonu kullanılan bir modele elma resmi verilip fonksiyondan 0.90 değeri alınıyorsa, resmin elma olma ihtimali %90’dır.

$$F(\text{net}) = 1 / (1 + e^{-\text{net}}) \quad (3.4)$$

3. Tanh (Hiperbolik Tanjant): Tanh fonksiyonu, girdileri -1 ile 1 arasında bir değere dönüştürür. Bu, bazen sigmoid fonksiyona göre daha iyi performans gösterir çünkü verileri sıfır merkezli hale getirir (Nokour ve Gülbandılar, 2023).

$$F(net) = (e^{net} - e^{-net}) / (e^{net} + e^{-net}) \quad (3.5)$$

4. Leaky ReLu: Bu, ReLu'nun bir varyasyonudur ve negatif girdiler için çok küçük bir gradyan (sızıntı) sağlar. Bu fonksiyon, ReLu'da görülen ölü nöron problemine bir çözüm sunar. Diğer fonksiyonlara göre hızlı hesaplama yapar (Bedi vd., 2022).

$$F(net) = \max(0.001 * net, net) \quad (3.6)$$

5. Softmax: Çok sınıflı sınıflandırma problemlerinde, çıktı katmanında kullanılan bir aktivasyon fonksiyonudur. Girdileri olasılık dağılımına dönüştürür, böylece her sınıf için bir olasılık elde edilir (Gao vd., 2020).

$$F(net) = e^{net} / (\sum_i^j e^{net}) \quad (3.7)$$

3.18.3.3. Döngü sayısı (epoch)

Bir döngü, tüm eğitim veri setinin sinir ağı tarafından tam olarak bir kez ileri ve geri yayılım yoluyla işlenmesi sürecidir. Yani bir döngüde ağ her bir örneği en az bir kere görür. Döngü sayısının belirlenmesi, modelin eğitim sürecinin ne kadar süreceğini ve veri üzerinde ne kadar tekrar yapacağını belirler. Çok az döngü kullanmak modelin yetersiz öğrenmesine çok fazla döngü kullanmak ise aşırı öğrenmeye yol açabilir (Brownlee, 2018). Döngü sayısını belirlerken, genellikle doğrulama veri seti üzerindeki performansı izlemek ve erken durdurma gibi teknikleri kullanmak faydalıdır. Bu, modelin ne zaman yeterince öğrendiğini ve eğitimin ne zaman durdurulması gerektiğini anlamaya yardımcı olur. Belirli bir döngüden sonra modelin öğrenme durumu oldukça azalır.

3.18.3.4. Öğrenme katsayısı

Öğrenme katsayısı, ağırlıkların güncellerken yapılan ayarın büyüklüğünü belirleyen bir hiperparametredir. Bu değer, her geri yayılım adımında ağırlık gradyanına göre ağırlıkların ne kadar değiştirileceğini ifade eder. Çok yüksek bir öğrenme katsayısı,

ağın en iyi çözüme hızla yaklaşmasını sağlayabilir ancak aynı zamanda en iyi çözümü kaçırmaya veya dalgalanma riski taşır. Çok düşük bir öğrenme katsayısı ise ağın çok yavaş öğrenmesine veya yerel minimumlarda takılmaya sebep olabilir (Bayır, 2006). Sabit bir öğrenme katsayısı yerine, eğitim sürecinde dinamik olarak ayarlanan öğrenme katsayıları kullanmak yaygındır. Örneğin, Adam optimizasyon algoritması, her bir parametre için adaptif öğrenme katsayıları kullanır.

3.18.3.5. Momentum katsayısı

Ağın daha iyi öğrenmesi için kullanılan bir katsayıdır. Ağın performansını artırmaya yardımcı olur. Hata oranını düşürür. Düşük öğrenme katsayısıyla yerel minimumlara ulaşmak zaman alır. Yüksek öğrenme katsayısıyla da salınım fazla olduğundan yerel minimuma ulaşmak imkânsız olur. Momentum katsayısı kullanılarak bir sıçrama yapılır ve sonuca ulaşılır (Ayşe ve Berberler, 2017).

3.18.4. Rassal orman yöntemi (random forest regression)

Rassal orman yöntemi hem sınıflandırma hem de regresyon problemlerinde kullanılabilen popüler bir modeldir. Karar ağaçlarının birleşiminden oluşur. En doğru sınıflama yapan karar ağaçlarını bir arada bulundurur (Coşar ve Deniz, 2021). Karar ağaçları doğru sorular soran ve başarılı tahminler yapabilen insanlara benzetilebilir.

Kullanımı kolay olduğu için ve hem sınıflama hem de regresyon problemleri için tercih edilebildiğinden yaygınlaşmış bir modeldir. Veri seti üzerinde çeşitli ağaç modelleri oluşturulur ve her bir model üzerinde ayrıntılı işlem yapılır. Her bir karar ağacı için tahmin değeri oluşturulur. Tahmin sonucu oluşan her değer için bir oylama gerçekleştirilir. Problem türü sınıflama ise en yüksek oyu alan değer alınır. Problem türü regresyon ise değerlerin ortalaması alınır (Miracöztürk, 2023).

Yaygın olarak kullanılan toplu sınıflandırıcılar rassal orman, hızlandırma ve torbalama yöntemleridir. Torbalama yöntemine rasgelelik eklenerek rasgele orman yöntemi elde edilmiştir. Karar ağaçlarının en büyük sorunu veriyi ezberlemesidir. Rassal orman yöntemi bu sorunu çözmek için hem veri setinden hem de özniteliklerden rassal olarak veri ve öznitelik grupları seçer. Rassal orman farklı veri setleri üzerinde çalıştığından


varyans düşüktür. Diğer bir avantajı ise bize özniteliklerin ne kadar önemli olduğunu verir (Akar ve Güngör, 2012).

Yapı içerisindeki her karar ağacı, veri setinin rastgele seçilen alt kümeleri üzerinde eğitilir. Ayrıca, her düğümde bölünme için dikkate alınan özellikler de rastgele seçilir. Bu rastgelelik, modelin aşırı öğrenmesini (overfitting) önlemeye yardımcı olur. Rassal orman, hangi özelliklerin tahmin yaparken en önemli olduğunu belirlemeye yardımcı olabilir. Bu, modelin hangi girdilerin çıktıyı en çok etkilediğini anlamamıza olanak tanır. Bu yöntem, eksik verilere ve aşırı değerlere karşı oldukça sağlamdır. Ayrıca, modelin veri setindeki gürültüye karşı toleranslı olmasını sağlar. Yöntemin başarısı, ağaç sayısı, özellik sayısı ve ağaç derinliği gibi hiperparametrelerin uygun bir şekilde ayarlanmasına bağlıdır.

Rassal orman yöntemi, geniş bir uygulama alanına sahiptir ve özellikle karmaşık veri yapılarına sahip problemlerde etkilidir. Ancak, modelin yorumlanabilirliği sınırlıdır çünkü çok sayıda karar ağacının birleşimi nedeniyle sonuçların arkasındaki mantığı anlamak zor olabilir.

3.18.5. Destek vektör makinesi (support vector machine)

Destek Vektör Makineleri destek vektör sınıflandırıcısı ve destek vektör regresörden oluşmaktadır. DVM sınıflandırma ve regresyon problemlerinde kullanılabilen denetimli bir öğrenme yöntemidir. İlk adımları Vapnik tarafından 1992 yılında atılan DVM günümüze kadar gelişerek gelmiştir (Meral ve Saraçlı, 2020). Şekil 3.16'da DVM'nin yapısı görülmektedir.




Şekil 3.16. Destek Vektör Makinesi Genel Yapısı (Uçak, 2012)

DVM'nin temelleri istatistiksel öğrenme teorisine dayanmaktadır. İki veya çok sınıflı problemlerin çözümü için geliştirilmiştir. Amaç sınıflara ait vektörler arasındaki mesafeyi maksimum yapmaktır (Ayhan ve Erdoğan, 2014).


3.18.5.1. Destek vektör sınıflandırma (support vector classifier)

DVM'de sınıflandırma problemleri yaygın olarak ikiye ayrılır. Birincisi doğrusal ayrılabilirlik, ikincisi ise doğrusal olmayan ayrılabilirlik problemidir. Verilerin doğrusal bir düzlemle ayrılabilmesi doğrusal ayrılabilirlik, verilerin doğrusal bir düzlemle ayrılamaması ise doğrusal olmayan ayrılabilirlik olarak adlandırılır. Gerçek hayatta veriler her zaman doğrusal ayrılmayabilir (Acı vd., 2017). Şekil 3.17'de doğrusal olarak ayrılabilen kırmızı ve yeşil noktalardan oluşan iki sınıf görülmektedir. Buradaki asıl amaç sonradan eklenecek bir noktanın hangi sınıfta yer alacağına karar vermektir. Bunun için iki sınıfı ayıran bir çizgi çizilir. Mavi çizgilerin yani sınır düzlemlerin arasında kalan bölgeye margin denir. Margin alanı ne kadar büyükse sınıflama başarısı o kadar yüksek olur.



Şekil 3.17. 2 Sınıflı Doğrusal Ayrılabilen Problem Örneği

Gerçek hayatta ki problemlere ait veri setlerinin doğrusal olarak ayrılması pek mümkün değildir. Şekil 3.18’de doğrusal olmayan bir durumun geometrik gösterimi yapılmıştır.



Şekil 3.18. 2 Sınıflı Doğrusal Ayrılmayan Problem Örneği

Doğrusal olmayan problemlerde sorunun çözümü içinin çeşitli çekirdekler (kernel) kullanılabilir. Bunlar arasında Radial Basis Function (RBF), polinomial, sigmoid ve doğrusal çekirdekler bulunur. Çekirdek seçimi, veri setinin yapısına ve problemin

özelliklerine bağlıdır (Ayhan ve Erdoğan, 2014). İki sınıflı doğrusal olmayan bir problemin çözümü için kural Eşitlik 3.8’de gösterilmiştir.

$$f(x) = \text{sign}(\sum a_i y_i \phi(x) \cdot \phi(x_j) + b) \quad (3.8)$$

Doğrusal olmayan sınıflandırma problemlerinde çekirdek fonksiyonu olarak aşağıdaki eşitlikler kullanılabilir.

$$\text{Doğrusal Çekirdek} \quad K(x_i, x_j) = x_i \cdot x_j \quad (3.9)$$

$$\text{Polinomial Çekirdek} \quad K(x_i, x_j) = (\gamma(x_i \cdot x_j) + c)^d \quad (3.10)$$

$$\text{Sigmoid Çekirdek} \quad K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) + c) \quad (3.11)$$

$$\text{Radyal Tabanlı Çekirdek} \quad K(x_i, x_j) = \exp(-\gamma |x_i - x_j|^2) \quad (3.12)$$


SVC modellerinin başarısı, çekirdek parametreleri ve düzenleme parametresi olan C'nin doğru şekilde ayarlanmasına bağlıdır. C değeri, modelin eğitim verilerine ne kadar uyum sağlayacağını belirler. Yüksek değerler aşırı uyumu (overfitting) artırabilirken, düşük değerler modelin yeterince uyum sağlamamasına neden olabilir. Modeller, karar sınırını anlamak ve yorumlamak açısından genellikle karmaşıktır. Büyük veri setlerinde eğitim süreleri uzun olabilir, ancak doğru ayarlandığında çok güçlü ve doğru sonuçlar üretebilirler (Kavzoğlu ve Çölkesen, 2010).

3.18.5.2. Destek vektör regresyon (support vector regression)

Destek vektör regresyon, destek vektör makinelerinin regresyon problemlerine uygulanan bir versiyonudur. Temel amacı, verilen bir veri seti için sürekli bir çıktı değeri tahmin etmektir. SVR, veri noktalarını en iyi şekilde temsil eden bir hiperdüzlem (veya doğru) bulmaya çalışır. Bu hiperdüzlem, verilen veri noktalarına mümkün olduğunca yakın olmalı ve aynı zamanda bu noktalardan olabildiğince uzakta olan diğer veri noktalarından ayrılmalıdır (Açıkkar ve Sivrikaya, 2020).

SVR’de tıpkı SVC’de olduğu gibi hem doğrusal hem de doğrusal olmayan problemlerin çözümünde kullanılabilir. Şekil 3.19’da iki yapının grafiği görülmektedir. SVR’de, belirlenen bir ϵ (epsilon) değeri kullanılarak, hiperdüzlem etrafında bir marj oluşturulur. Bu marj içindeki veri noktaları, model tarafından hata olarak kabul edilmez. Yani, model, bu marj içindeki tahminleri kabul edilebilir hata sınırları içinde olarak değerlendirir. SVR,

kayıp fonksiyonu olarak ε -duyarlı kaybı kullanır. Bu, modelin sadece marjın dışındaki veri noktalarına odaklanmasını sağlar. Marjın içindeki hatalar göz ardı edilir. Doğrusal olmayan problemler için, çekirdek yöntemleri (kerneltricks) kullanılarak veri, daha yüksek boyutlu bir uzaya dönüştürülür. SVR'nin performansı, çekirdek seçimi (örneğin RBF, polinomiye, sigmoid) ve hiperparametreler (C, epsilon, çekirdek parametreleri) üzerinde büyük ölçüde bağlıdır. C değeri, modelin eğitim verilerine ne kadar uyum sağlayacağını ve epsilon değeri, kabul edilebilir hata marjını belirler (Demirezen ve Çetin, 2021).



Şekil 3.19. Doğrusal (solda) ve Doğrusal Olmayan (sağda) SVR Örneği (Erol vd., 2021)


SVR, aşırı değerlere ve modelin aşırı öğrenmesine karşı oldukça dayanıklıdır. SVR, finansal verilerin tahmini, hava durumu tahminleri, enerji tüketimi tahminleri gibi birçok farklı alanda kullanılır. Güçlü ve esnek bir model olmasına rağmen, doğru çekirdek ve hiperparametre ayarlarının seçilmesi önemlidir. Hesaplama maliyetinin yüksek olması ve model yorumlanabilirliği de SVR'yi kullanırken dikkate alınması gereken diğer faktörlerdir.

3.18.6. Doğrusal regresyon (linear regression)

Doğrusal regresyon bilinen bir veri değerini kullanarak bilinmeyen bir veri değerini tahmin edebilen makine öğrenmesi yöntemidir. Bilinen veya bağımsız değişkenlerle bilinen veya bağımlı değişken arasında doğrusal olarak matematiksel bir ilişki kurar

(Aalen, 1989). Örneğin geçen seneki gelir ve harcamalarımız ele alındığında, geliri bağımsız değişken ve harcamayı da bağımlı değişken olarak düşünersek ve harcamalarımız gelirin yarısı kadar ise bir sonraki senenin gelirini bilirsek doğrusal regresyon mantığıyla harcamalarımızın da bir sonraki senenin gelirinin yarısı olduğunu söyleriz.

Şekil 3.20’de yer alan grafiğin x eksenini bağımsız değişken ve y eksenini de bağımlı değişken olarak düşünersek bağımlı ve bağımsız değişkene ait verileri temsil eden noktalara en uygun doğrusal çizgi grafiği oluşturmak doğrusal regresyonun amacıdır (Yao ve Li, 2014).



Şekil 3.20. Doğrusal Regresyon Grafiği (Keramati ve Hamdullahpur, 2022)

Eşitlik 3.13’de bir bağımlı değişken ve bir bağımsız değişken arasındaki matematiksel ilişki formül olarak verilmiştir. Y bağımlı değişkeni, x ise bağımsız değişkeni ifade eder. Formülde yer alan ε değeri x ile y arasında doğrusal olarak açıklanamayan durumu ifade eder. Eğer ε değeri sıfır olsaydı x değerinin bilinmesi durumunda y değeri de bilinirdi. Formüldeki β_0 doğrunun y eksenini kestiği noktayı ifade ederken β_1 ise regresyon katsayısını yani eğimi ifade eder. Eşitlik 3.14 ise bağımsız değişkenin birden fazla olması durumunda kullanılır (Şahinler, 2000).

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (3.13)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_n x_n + \varepsilon \quad (3.14)$$

Doğrusal regresyonla bulunmak istenen bağımlı değişkenin sıralı veya sürekli sayısal verilerden oluşması gerekmektedir. Kategorik veri olmaması gerekir. Yapı içerisindeki bağımsız değişkenlerinde sayısal olması istenir ama bazı durumlarda kategorik de olabilir.

Doğrusal regresyonun birçok çeşidi vardır, bunlar genellikle uygulama alanlarına ve modelin karmaşıklığına göre değişiklik gösterir. Tek bir bağımsız değişken kullanılarak tek bağımlı değişkeni tahmin etmeye çalışmak için basit doğrusal regresyon kullanılır. Bağımsız değişken sayısının iki veya daha fazla olması durumunda ise çoklu doğrusal regresyon kullanılır (Kılıç, 2013). Polinom regresyon çoklu doğrusal regresyonun özel bir durumudur. Tek bir bağımsız değişken bulunur. Karmaşık ilişkilerin modellenmesi sağlanır (Özen vd., 2021). Bazı problemlerin çoklu regresyon modeli ile çözümü yapılırken sorunlarla karşılaşılır. Bağımlı değişkeni en çok etkileyen bağımsız değişken kestirilemez. Parametre tahmini için ridge regresyonu kullanılabilir. Bu regresyonda amaç minimum varyansla parametreyi tahmin etmektir. Böylece modelin karmaşıklığı azalır (Büyükuysal ve Öz, 2016). Lasso regresyonu Ridge regresyonuna benzer. Amaç katsayıları sıfıra indirerek modeli basitleştirmek ve daha az değişkenle problemi çözmektir. Lasso regresyonunda görülen bazı eksiklikler üzerine Lasso ve Ridge regresyonlarının birlikte kullanılmasıyla Elastik-Net regresyonu ortaya çıkmıştır. Bu modelde katsayılar küçültülmekte ve istenilen değişkenler seçilmektedir (Vergili ve Orhan, 2022). Lojistik regresyon aslında doğrusal değildir. Ancak doğrusala dönüştürülebilir bir modeldir. Yorumlaması zor olmadığından tercih edilen bir modeldir. Bağımlı değişken kategoriktir. Yani evet/hayır, başarılı/başarısız gibi ikili değerler alır. Bağımlı ve bağımsız değişkenler arasında logit ilişki vardır. Bağımsız değişkenin süreksiz ya da sürekli olması gibi bir şart yoktur (Baydemir, 2014).

Doğrusal regresyon, veri biliminde en temel yöntemlerden biridir ve geniş bir uygulama alanı vardır. Ancak, modelin varsayımlarının doğrulanması ve uygun veri setleriyle kullanılması önemlidir. Model kullanılırken bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki olmasına, hataların varyansının sabit olmasına, gözlemlerin birbirinden bağımsız olmasına, hataların normal dağılım göstermesine dikkat edilmelidir. Doğrusal regresyon talep tahmini, fiyat analizi gibi konularda yaygın olarak kullanılır.

3.18.6.1. En küçük kareler yöntemi

Doğrusal regresyonda iki veya daha fazla değişken arasındaki ilişkiyi açıklamak için bir model kurulur. En küçük kareler yöntemiyle kurulan bu modelin gerçek modele ne kadar yaklaştığı, regresyon modelinin veriye ne kadar uyduğu tespit edilir (Özgül ve Alma, 2008)


Eşitlik 3.15’de verilen formülde y bağımlı değişkeni, x bağımsız değişkeni, a eğimi ve b ise doğrunun y eksenini ile kesişimini belirtir. Her bir veri noktası için, modelin tahmin ettiği değer ile gerçek değer arasındaki hata farkı hesaplanır. En küçük kareler yöntemi, bu hataların karelerinin toplamını minimize etmeyi hedefler. Hataların karelerinin toplamını minimize etmek için, genellikle diferansiyel hesap yöntemleri kullanılır. A ve b parametreleri için türevler alınır ve bu türevlerin sıfıra eşit olduğu noktalar bulunur. Bu işlem, en iyi a ve b değerlerini verir. Elde edilen a ve b değerleri, veri setimize en iyi uyan doğruyu tanımlar. Bu doğru, veri noktalarının genel eğilimini temsil eder.

$$y = ax + b \quad (3.15)$$

3.18.7. K-en yakın komşu (k-nearest neighbor)

K-en yakın komşu algoritması hem sınıflama hem de regresyon problemlerinde kullanılan bir denetimli öğrenme yöntemidir. Gözlemlerin birbirlerine olan yakınlıkları üzerinden tahmin yapılmaya çalışılır (Peterson, 2009). Bu algoritmada tahminde bulunmak istediğimiz niteliklere en yakın K adet nitelik grubu veri seti içerisinde seçilir. Veri seti içerisindeki bu nitelik grubuna ait sonuçların ortalaması alınarak tahminde bulunma işlemi sonlandırılır (Kramer, 2013).

Bu algoritma ile mevcut verilerin hangi sınıfta olduğuna bakılarak yeni girilen verinin hangi sınıfa ait olabileceğine karar verilir (Putra ve Juanita, 2021). Şekil 3.21’de iki sınıfa ait olan verilerin oluşturduğu grafik görülmektedir. Bu yapının içerisine sarı renkle belirtilen yeni veri girişi yapıldığında, K değerinin 3 alınması durumunda kendisine en yakın 3 eleman seçilir. Grafiğe göre üç elemanın ikisi kırmızı sınıfta biri ise mavi sınıftadır. Bu duruma göre KNN yeni eklenen verinin sayısal üstünlükten ötürü kırmızı sınıfta olduğunu bize söyler.



Şekil 3.21. K En Yakın Komşular Algoritması İçin İki Sınıflı Örnek

Sisteme eklenen yeni veri ile mevcut veriler arasındaki uzaklık hesaplamaları Öklid, manhattan, minkowski, hamming gibi fonksiyonlarla yapılır.

1. **Öklid Uzaklığı:** Sınıflama ve kümeleme işlemlerinde sık kullanılan bir uzaklık ölçütüdür. İki öge arasındaki gerçek uzaklığı bulmak için kullanılır. K-NN algoritmasındaki temel uzaklık ölçütüdür (İnce, 2021). Öklit uzaklığı formülü Eşitlik 3.16'daki gibidir.

$$d_E(x, y) = \sqrt{\sum_{i=1}^N (x_i - y_i)^2} \quad (3.16)$$

2. **Manhattan Uzaklığı:** n boyutlu bir düzlemdeki iki nokta arasındaki uzaklıkların mutlak değerlerinin toplamı bize sonucu verir. Bu teknikte sınıflama ve kümeleme algoritmalarında tercih edilen bir tekniktir (Taşçı ve Onan, 2016). Manhattan uzaklığı Eşitlik 3.17'ye göre hesaplanır.

$$D = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.17)$$

3. **Minkowski Uzaklığı:** Öklid ve Manhattan uzaklığı gibi uzaklık hesaplamalarının genel formülüdür. Hesaplama Eşitlik 3.18'e göre yapılır.

$$D = ((\sum_{i=1}^k |x_i - y_i|^p)^{1/p}) \quad (3.18)$$

4. **Hamming Uzaklığı:** İkili veri dizileri arasındaki uzaklığı bulmak için kullanılan bir tekniktir. Boyutları aynı olan iki dizi arasındaki değerler karşılaştırılır. Farklılıklar varsa bunların sayısı alınır. Hamming uzaklığı kaç özelliğin farklı olduğunu verir (Korkut vd., 2018). Hesaplama Eşitlik 3.19'a göre yapılır.

$$D_H = \sum_{i=1}^k |x_i - y_i| \quad (3.19)$$

3.18.7.1. K değerinin belirlenmesi

KNN tekniğinin çalışmasına göre önemli unsurlardan bir tanesi k sayısının belirlenmesidir. Uygun k değerinin seçilmesi sınıflama başarısı için önemlidir. Genellikle k değeri veri seti içerisindeki özniteliklerin sayısının yarısı ya da karekökü olacak değerde ayarlanır (Yılmaz, 2019). İdeal k değeri deneme yanılma yoluyla veya çapraz doğrulama metoduyla da bulunabilir.

1. **Deneme Yanılma Yöntemi:** Veri seti, genellikle eğitim ve test setleri olarak ikiye bölünür. Çeşitli K değerleri için model eğitilir ve test seti üzerinde performansları değerlendirilir. Her bir K değeri için, sınıflandırma hatası oranı hesaplanır. En düşük hata oranına sahip K değeri ideal olarak kabul edilir.
2. **Çapraz Doğrulama (Cross-Validation) Kullanımı:** Veri seti, eşit büyüklükteki 'K' parçaya ayrılır. Her parça sırayla test seti olarak kullanılırken, kalan kısım eğitim seti olarak kullanılır. Her bir K değeri için, çapraz doğrulama sırasında elde edilen ortalama hata oranları hesaplanır. En düşük ortalama hata oranına sahip K değeri tercih edilir.

Bunların haricinde model performans metrikleri de dikkate alınarak k değeri değiştirilebilir. Model çalıştırdıktan sonra performans metriklerinden alınan sonuca göre k değeri artırılabilir veya azaltılabilir. Son olarak uygulama alanına göre ideal k değeri değişebilir. Bazı durumlarda, alan uzmanlarının önerileri yararlı olabilir. Büyük veri setleri, daha büyük bir k değeri gerektirebilir. Ancak, çok büyük k değerleri, modelin aşırı genellemesi riskini artırabilir. KNN algoritması anlaşılması ve uygulanması kolaydır. Modeli eğitmek için herhangi bir öğrenme süreci gerekmez. Bu, tembellik temelli bir algoritma olarak da adlandırılır. Farklı türde özelliklere sahip veri setleri üzerinde iyi sonuçlar verebilir. Ancak büyük veri setleri ile çalışırken hesaplama maliyeti yüksektir.

Eğitim veri setindeki sınıflar dengesiz ise, algoritmanın performansı etkilenebilir. Tüm özellikler eşit ağırlıkta kabul edilir. Bu durum da bazı durumlarda yanıltıcı olabilir. Uygun bir k değerinin belirlenmesi deneme yanılma yoluyla yapılır ve veri setine özgüdür.


KNN, basitliği ve verimliliği nedeniyle birçok alanda kullanılır. Bu alanlar arasında tıbbi teşhis, kredi derecelendirme, öneri sistemleri ve daha pek çok yer alır. Özellikle küçük ve orta ölçekli veri setlerinde tercih edilir. Büyük veri setleri ve özellik seçimi konularında bazı zorluklar sunar. Optimal performans için veri ön işleme ve uygun bir k değerinin seçilmesi önemlidir. Farklı özelliklerin farklı ölçeklerde olması, KNN algoritmasının performansını olumsuz etkileyebilir. Bu yüzden, tüm özelliklerin standardizasyonu veya normalizasyonu önemlidir. KNN, gürültülü verilere karşı hassastır. Bu yüzden, aykırı değerlerin ve eksik verilerin temizlenmesi önemlidir. Alakasız veya az önemli özelliklerin modelden çıkarılması, modelin performansını artırabilir.

3.18.8. Lojistik regresyon (logistic regression)

İsminde regresyon geçmesine rağmen bir sınıflandırma algoritmasıdır. İki sınıflı problemlerde sıkça kullanılabilir. Doğrusal regresyondan en önemli farkı ise iki sınıfın birbirinden ayrılırken aradaki çizginin nasıl uygulandığıdır. Doğrusal regresyonda iki sınıf birbirinden ayrılırken çizgiyi çizmek için en küçük kareler yöntemi kullanılırken, lojistik regresyonda ise maksimum olabilirlik yöntemi kullanılır (Nick ve Campbell, 2007). Lojistik regresyon sosyal ve biyolojik bilimlerde sıkça kullanılmaktadır. Sosyal bilimler alanındaki problemlerin çoğunda bağımlı değişkenin iki değerden birini alabilmesi durumu söz konusudur. Örneğinin kişinin cinsiyetinin erkek ya da kız olması gibi. Bağımlı değişkenin ya da çıktı değişkeninin kategorik veri olması durumunda lojistik regresyon çoklu regresyonun uzantısı gibi kullanılır (Oğuzlar, 2005).

Lojistik regresyon verileri sınıflandırmak için grafiği Şekil 3.22’de verilen sigmoid fonksiyonunu kullanır. Bu fonksiyonun amacı verileri 0-1 aralığına yerleştirmektir. Denklem Eşitlik 3.20’deki gibidir.

$$g(z) = 1 / (1 + e^{-z}) \quad (3.20)$$



Şekil 3.22. Sigmoid Fonksiyonu Grafiği

Yaygın olarak kullanılan birkaç lojistik regresyon türü vardır. Lojistik regresyonun türü tahmin edilecek sonucun doğasına ve kullanılan bağımsız değişkenin sayısına göre değişmektedir. İki ihtimalli bir sonuç tahmin etmek için ikili lojistik regresyon kullanılırken, birden çok bağımsız değişkenin söz konusu olduğu problemlerde çoklu lojistik regresyon kullanılır (LaValley, 2008).

Lojistik regresyon, sonuçların oranlarını kullanarak analiz yapar ve bu oranlar üzerindeki etkileri inceler. Modelin performansı genellikle karışıklık matrisi, ROC eğrisi ve AUC skoru gibi metriklerle değerlendirilir. Lojistik regresyon, basitliği ve yorumlanabilirliği nedeniyle birçok alanda popüler bir seçenektir. Ancak, veri setinin karmaşıklığına ve ihtiyaçlara bağlı olarak daha gelişmiş yöntemler gerekebilir.

3.18.9. Naive bayes yöntemi

Naive bayes sınıflandırıcısı temeli bayes teoremine dayalı olan denetimli öğrenme algoritmasıdır. Düzenli olmayan veri kümelerinde kullanılabilir. Her bir eleman için olasılık hesabı yapılır. Bütün sınıflar için olasılık değerlerine bakılır. Değeri en yüksek olan sınıf neyse elemanı o sınıfa yerleştirilir. Sınıflama bu mantıkla yapılır (Şahinaslan vd., 2022). Bayes karar teoremi Eşitlik 3.21’de yer almaktadır.

$$P(S_i | X) = P(X | S_i) P(S_i) / P(X) \quad (3.21)$$

X : Seçilen örnek

I	:	Sınıf
$P(S_i X)$	:	Örneğin i sınıfına ait olma ihtimali
$P(S_i)$	:	İlk olasılık
$P(X)$	:	Seçilen örneğin X olma olasılığı
$P(X S_i)$	:	i sınıfına ait örneğin X olma olasılığı

Naive bayes sınıflandırıcısı niteliklerin hepsini eşit derece önemli ve niteliklerin hepsini birbirinden bağımsız kabul eder. Gerçek hayatta niteliklerin hepsi birbirinden bağımsız olmasa da bu algoritmayla başarılı sonuçlara ulaşılır (Solmaz vd., 2014).

Veri türlerine uygun çeşitli Naive bayes modelleri bulunmaktadır. En yaygın olanları Gaussian Naive Bayes, Multinomial Naive Bayes ve Bernoulli Naive Bayes'tir. Naive Bayes'in basit yapısı ve hesaplama verimliliği, özellikle büyük veri setleri ve gerçek zamanlı uygulamalar için onu cazip bir seçenek yapar. Ancak, özellikler arasındaki bağımlılıkların göz ardı edilmesi bazı durumlarda modelin performansını olumsuz etkileyebilir.

3.18.10. Gaussian naive bayes

Gaussian Naive Bayes, Naive Bayes sınıflandırıcı ailesinin bir üyesidir ve özellikle sürekli veri üzerinde etkili bir şekilde çalışmak üzere tasarlanmıştır. Bu yöntem, özelliklerin normal (gaussian) bir dağılıma sahip olduğunu varsayar. Bu varsayım, sürekli ve normal dağılım gösteren verilerle çalışırken oldukça kullanışlıdır (Karatay ve Algahani, 2021).

Gaussian Naive Bayes, her bir özelliğin, her bir sınıf içinde normal dağılım gösterdiğini varsayar. Her özellik ortalama ve standart sapma gibi parametrelerle tanımlanabilir. Özellikle biyoloji, tıp, finans gibi alanlarda sürekli verilerin sınıflandırılmasında kullanılır. Modelin yapısı basit olduğundan, büyük veri setleri üzerinde hızlı bir şekilde çalışabilir. Gerçek dünyadaki verilerde özellikler arasında tam bağımsızlık nadiren bulunur. Bu, modelin performansını olumsuz etkileyebilir. Bu model, veri setindeki her bir özelliğin dağılımını ayrı ayrı inceleyerek ve bu dağılımların sınıflandırma kararına

katkıda bulunma şeklini modelleyerek çalışır. Bu durum sürekli ve normal dağılıma yakın veriler için oldukça etkili bir yaklaşımdır.

3.19. Veri Madenciliği Algoritmalarında Performans Ölçümü

Makine öğrenmesi yöntemleri ile sınıflama veya regresyon çalışmaları yaparken istenen sonucun ne kadar başarılı olduğunu görmek için çeşitli performans ölçüm yöntemleri kullanılır (Yıldırım, 2021). Çok sayıda makine öğrenmesi yöntemi mevcuttur. Bir problemin çözümü için en doğru sonucu verecek makine öğrenme yöntemi kullanılmak istenir. Bu durumunda her bir modelin performansı ölçülür ve en başarılı sonucu veren model kullanılır. Bir diğer husus ise veri seti içerisinde yer alan eğitim ve test verilerinin başarılarının karşılaştırılmak istenmesidir. Performans metrikleri veri kümesine ve test kümesine ayrı ayrı uygulanarak kıyaslama yapılır. Böylece sorun varsa soruna müdahale edilir (Devreyakan, 2023). Çeşitli hata metrikleri vardır. Her bir metrik, modelin farklı yönlerini ölçer. Bu yüzden problem tipi ve veri setinin özelliklerine göre uygun metrikler seçilmelidir. Özellikle sınıflandırma problemlerinde, sınıf dengesizliği gibi faktörler dikkate alınmalıdır. Bazı yaygın performans metrikleri ve bunların detayları şu şekildedir:

3.19.1. Ortalama mutlak yüzde hata(mean absolute percentage error–MAPE)

Tahmin sonuçlarını gerçek sonuçlarla karşılaştırarak aradaki hatayı yüzdelik olarak ifade eder. Sıkça kullanılan bir yöntemdir. Ancak gerçek değerler arasında 0(sıfır) değeri varsa bölme işleminde hata oluşacağından hatalı sonuç elde edilir. Düşük tahminlerde hata %100'ü geçemez fakat tahmin değerleri gerçekten çok uzaksa hata oranı için üst sınır yoktur (Özen vd., 2021). MAPE değerinin %10'un altında olması başarının çok iyi, %10 ile %20 arasında olması başarının iyi, %20 ile %50 arasında olması başarının kabul edilebilir, %50'nin üzerinde olması ise başarının kabul edilemez olduğunu gösterir (Usta, 2022).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \quad (3.22)$$

y_i	:	Gerçek değer
y'_i	:	Tahmin edilen değer
n	:	Gözlem sayısı

3.19.2. Ortalama mutlak hata (mean absolute error - MAE)

Veri seti içindeki gerçek veriler ile tahminler arasındaki farkların mutlak değerleri alınır. Sonuçlar toplanarak örnek sayısına bölünür. Sonuç sıfır ile sonsuz arasında değişir. Sonuç sıfıra ne kadar yakınsa o kadar başarılı olunur (Aydın, 2018).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (3.23)$$

y_i : Gerçek değer
 y'_i : Tahmin edilen değer
 n : Gözlem sayısı

3.19.3. Ortalama kare hatası (mean square error - MSE)

Veri setindeki gerçek veriler ile tahminler birbirlerinden çıkarılarak sonucun karesi alınır. Her bir örnek için elde edilen sonuçlar toplanır. Toplam sonuç veri setindeki örnek sayısına bölünür. Büyük hatalara daha fazla önem verir. Veri setinde aykırı değerler olması durumunda MSE değeri yüksek çıkar (Yurttabir ve Şen, 2021).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (3.24)$$

y_i : Gerçek değer
 y'_i : Tahmin edilen değer
 n : Gözlem sayısı

3.19.4. Kök ortalama kare hata (root mean square error - RMSE)

MSE değerinin karekökü alınarak hesaplanır. Gerçek değerlerle tahmin edilen değerler arasındaki farkın yani tahmin hatalarının standart sapmasıdır. RMSE değeri sıfır ise model hiç hata yapmamıştır anlamındadır. RMSE değeri 0 ile sonsuz arasında değişebilir (Gezmez, 2022).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (3.25)$$

y_i : Gerçek değer
 y'_i : Tahmin edilen değer

n : Gözlem sayısı

3.20. Normalizasyon

Veri madenciliğinde normalizasyon, veri setindeki değişkenlerin ölçeklerini standartlaştırma sürecidir. Bu süreç, farklı ölçeklere sahip veri özelliklerini karşılaştırılabilir hale getirir ve birçok makine öğrenmesi algoritmasının daha etkin çalışmasını sağlar (Saranya ve Manikandan, 2013). Normalizasyonun önemi şu maddelerle anlatılabilir:

- Farklı özellikler genellikle farklı ölçeklere sahiptir (örneğin, yaş ve gelir). Bu ölçek farklılıkları, bazı algoritmaların veri setini yanlış yorumlamasına yol açabilir.
- Normalizasyon, tüm özellikleri ortak bir ölçeğe getirerek bu sorunu çözer.
- Özellikle mesafe tabanlı algoritmalar için normalizasyon kritiktir çünkü bu algoritmalar, özellikler arası mesafeleri hesaplar.
- Normalizasyon, tüm özelliklerin eşit derecede önemsenmesini sağlar, böylece büyük ölçekli özelliklerin baskın çıkmasını önler.
- Normalizasyon, özelliklerin daha düzenli bir aralığa sıkıştırılmasını sağlar Böylece algoritmalar daha hızlı ve etkin bir şekilde öğrenir.
- Normalizasyon, modelin daha genelleştirilebilir olmasına yardımcı olur ve aşırı uyum riskini azaltabilir.
- Özellikle yüksek boyutlu veri setlerinde, normalizasyon modelin karmaşıklığını ve aşırı uyuma eğilimini düşürebilir.
- Normalleştirilmiş veriler, özelliklerin önemini ve etkisini daha net bir şekilde gösterir.
- Veri analisti veya model geliştirici için, normalleştirilmiş veriler üzerinde çalışmak, sonuçların yorumlanmasını kolaylaştırır.

Veri madenciliği ve makine öğrenmesinde normalizasyon, veri setinin daha homojen ve işlenmesi daha kolay hale gelmesini sağlar. Bu süreç, algoritmaların daha doğru ve hızlı çalışmasına, ayrıca model sonuçlarının daha iyi yorumlanmasına olanak tanır. Normalizasyon, özellikle farklı özelliklerin öneminin eşitlenmesini ve modelin daha genel bir yapının kazanmasını sağlar.

3.20.1. Minimum maksimum (min-max) normalizasyon yöntemi

Genellikle mühendislik problemlerinde tercih edilen, yaygın olarak kullanılan bu yöntem verileri lineer olarak belirli bir aralığa sıkıştırır. İşlemden sonra veriler arasındaki ilişki aynen korunur. Sıkıştırma aralığı genellikle 0-1 aralığında olur. Ancak problemin türüne göre bu aralık istenilen boyuta getirilebilir (Yüce ve Özkan, 2021).

$$x' = \frac{(x_i - x_{min})}{(x_{max} - x_{min})} \quad (3.26)$$

x'	:	Normalize edilmiş değer
x_i	:	Normalize edilecek değer
x_{max}	:	Veri seti içerisindeki en büyük değer
x_{min}	:	Veri seti içerisindeki en küçük değer

Bu yöntemin amacı, farklı özelliklerin veri setinde benzer ölçeklere sahip olmasını sağlamak ve böylece algoritmanın her bir özelliği eşit ağırlıkta değerlendirmesine olanak tanımadır. Özellikler arasında büyük ölçek farklılıkları olduğunda bu yöntem etkilidir. Örneğin, bir özellik milyonlarca birim aralığında iken diğer bir özellik yalnızca birkaç birim aralığında olabilir. Bu durumda, min-max normalizasyonu özellikler arasındaki bu dengesizliği düzeltmeye yardımcı olur.

3.20.2. Ondalık ölçekleme normalizasyon yöntemi

Bu yöntem veri seti içerisinde yer alan değerleri 1'den küçük yapmayı amaçlar. Bunun için de değerleri 10 veya 10'un katları olacak sayılara böler. Genellikle veri setindeki en büyük mutlak değere göre ölçekleme yapılır (Cihan vd., 2017).

$$A' = \frac{A_i}{10^j} \quad (3.27)$$

A'	:	Normalize edilmiş değer
A_i	:	Normalize edilecek değer
10^j	:	Veriyi 1'den küçük yapan değer

Bu yöntemin amacı, verileri daha yönetilebilir bir aralığa getirerek veri setindeki farklılıkları daha etkin bir şekilde yansıtmaktır. Ondalık ölçekleme, özellikle büyük

sayısal değerler içeren veri setlerinde kullanışlıdır. Çünkü bu sayıları daha küçük ve işlenmesi daha kolay bir aralığa dönüştürür. Bu durum algoritmaların daha hızlı ve daha etkili bir şekilde çalışmasını sağlayabilir.

3.20.3. Z-Skor normalizasyon yöntemi

Veri seti içerisinde uç değerler olabilir. Bu uç değerler sonuca çok fazla etki edebilir. Bu uç değerlerin sonuca diğer değerler gibi eş şekilde etki edebilmesi için Z-skor normalizasyonu uygulanır (Han vd., 2021).

$$x' = \frac{x_i - \mu_i}{\sigma_i} \quad (3.28)$$

x_i	:	Normalize edilecek değer
μ_i	:	Veri setinin ortalama değeri
σ	:	Verideki standart sapma

Z-skor normalizasyonu, veriyi ortalama etrafında merkezler, bu da verilerin ortalama değere göre ne kadar varyasyon gösterdiğini anlamamızı sağlar. Verileri standart bir ölçeğe dönüştürür. Böylece farklı özellikler arasında doğrudan karşılaştırma yapılabilir. Anormal değerler Z-skor ile kolayca tespit edilebilir. Bu yöntem, özellikle verilerin normal dağılıma sahip olduğu veya bu dağılıma yakın olduğu durumlarda etkilidir. Makine öğrenimi ve istatistiksel analizlerde yaygın olarak kullanılır.

3.20.4. Norm normalizasyon yöntemi

Bu yöntemde öncelikle her bir özelliğe ait değerlerin karesi alınarak toplanır. Toplamın karekökü alınarak norm değer hesaplanmış olur. Son olarak her bir değer bulunan norm değere bölünerek normalizasyon tamamlanır (Yüce ve Özkan, 2021).

$$|x| = \sqrt{x_1^2 + x_2^2 + x_3^2 + \dots x_i^2} \quad (3.29)$$

$|x|$: Normalize edilecek veriler için norm değeri

$$x' = \frac{x_i}{|x|} \quad (3.30)$$

x_i : Normalize edilecek değer

Bu normalizasyon yöntemi, özellikle makine öğrenimi ve veri madenciliğinde, özellik vektörlerini ölçeklendirmek ve farklı özellikler arasındaki ilişkileri korumak için kullanılır.

3.20.5. Sigmoid normalizasyon yöntemi

Bu yöntemde sigmoid fonksiyonu kullanılarak veriler 0 ile 1 veya -1 ile 1 aralığına sıkıştırılır. Makine öğrenimi ve derin öğrenme uygulamalarında etkili sonuçlar alınmasını sağlar. Çünkü birçok makine öğrenimi algoritması verilerin 0 ve 1 arasında olmasını tercih eder (Jayalakshmi, 2011).

$$x' = \frac{1}{1+e^{-x_i}} \quad (3.31)$$

x_i : Normalize edilecek değer

e : Doğal logaritma değeri

Bu yöntem girdileri düzgün ve sürekli bir şekilde dönüştürür, böylece orijinal veri noktalarının arasındaki ilişkiler korunur. Sigmoid normalizasyonu, veri setindeki aşırı değerler tarafından etkilenebilir. Eğer veri setinde çok büyük ya da çok küçük değerler varsa, sigmoid fonksiyonu bu değerleri sırasıyla yaklaşık 1 veya 0'a dönüştürecektir. Bu durum, bu değerlerin normalleştirilmiş değerler üzerindeki etkisini azaltır. Bu nedenle, sigmoid normalizasyonu uygulanmadan önce veri setindeki aşırı değerlerin ele alınması gerekebilir.

3.21. Veri Analizi İçin Programlama Dili Seçimi

Veri analizi için Python, R, Scala, SQL, SAS, Java, Matlab ve Julia gibi programlama dilleri tercih edilebilir. Bu dillerin seçimi kişisel tercihlere, veri türüne, proje ölçeğine göre değişim gösterebilir. R dili ile karmaşık matematik problemleri kolay bir şekilde çözülebilir. Veri analizi ve veri madenciliği alanlarında tercih edilen bu dil verileri görselleştirebilme ve çizim yapabilme özelliklerine sahiptir. Kodlama yapısı kolaydır. Geliştirilen algoritmalar R dilinde kolayca yazılabilir. R dili ve geliştirme ortamı ücretsiz olarak kullanılabilir (Kılınç vd., 2016). Scala programlama dili 2003 yılında kullanılmaya başlamıştır. Sınıf yapısının olduğu fonksiyonel bir dildir. Programlama diliyle

uğraşanların ihtiyaçları doğrultusunda geliştirilebilir şekilde tasarlanmıştır. Scala dilinin kendine özgü özelliği azdır. Genellikle farklı programlama dillerinden esinlenilerek ortaya çıkarılmıştır. JVM platformu üzerinde çalıştırılır. Yeni bir dil olmasına rağmen büyük firma ve kurumlarca tercih edilir. (Sayar ve Ergün, 2014). Veri biliminde rağbet gören dillerden biri de SQL'dir. Veri biliminin temel taşlarından biri de veri tabanıdır. Veriler için veri tabanı oluşturulması, verilerin anlamlandırılması ve yapılandırılması için SQL dilinden faydalanılır (Çelik, 2018). SAS hem bir paket program hem de programlama dilidir. Kodlamanın yapılabilmesi için gerekli olan paket program ücretli ve lisanslıdır. Büyük firmalarca tercih edilir. Büyük veriler üzerinde veri yönetimi ve istatistiksel analizleri yapabilen SAS yazılımı bilim insanlarınca tercih edilir (Eskici ve Koçak, 2018). Büyük veri günümüzde eğitim, bankacılık, sağlık, enerji gibi alanlarda yer almaktadır. Büyük verinin yönetimi için çok sayıda sistem geliştirilmiştir. Bu sistemlerin çalışabilmesi bazı programlama dilleriyle sağlanır. Önemli programlama dillerinden bir tanesi de javadır (Karabay ve Ulaş, 2017). Java nesneye dayalı bir programlama dilidir. Bu dille geliştirilen uygulamalar çok sayıda sınıf içerir. Web uygulamalarının geliştirilmesinde tercih edilir. Derin öğrenme ve yapay zeka alanlarında veri yönetimi için tercih edilen kararlı yapıya sahip popüler bir dildir (Tungut, 2021). Matematiksel işlemlerin yapılması için geliştirilen matlab diliyle istatistiksel hesaplamalar ve veri analizi yapılabilir. Yüksek performanslı matlab diliyle işlemlerin görselleştirilmesi sağlanabilir. Robotik alanda yaygın olarak kullanımı vardır. Derlenen dillere göre yavaştır. Zor ve karmaşık işlerde tercih edilen bu dil kullanımı basit olmasıyla birlikte bireysel kullanımlarda maliyetlidir. Çünkü ticari amaçla geliştirilmiştir. Kurumsal kullanımlarda daha avantajlıdır (Yayla, 2019). Veri biliminde tercih edilen programlama dillerinden biri olan julia yeni bir dildir. Veri biliminde karşılaşılan sorunların üstesinden gelmek için ortaya çıkarılmıştır. Sayısal hesaplamalar, bilimsel uygulamalar, makine öğrenimi ve yapay zeka uygulamaları için kullanılabilen julia dili açık kaynak kodludur. Bilgisayar kaynaklarını yormayan bu dil hız konusunda performanslıdır. Öğrenmesi kolaydır ve farklı programlama dillerinin kütüphanelerini kullanabilir. (Özden ve Turanlı, 2023).

3.21.1. Python programlama dili

Bir programlama dilinin işlevselliği çağın ihtiyaçlarına karşılık verebilmesiyle ve sürdürülebilir olmasıyla doğru orantılıdır. Örneğin ilk çıktığında yaygın bir kullanıma sahip olan Pascal dilinin günümüzde kullanımı oldukça azdır. Python dili ise ortaya çıktığı ilk günden günümüze kadar yaygın olarak kullanılan, çoğu alanda üzerinde uygulama geliştirilebilen bir dil olmuştur. Python dilinin üniversitelerde programlama derslerinde gösterilmesi, köklü teknoloji firmalarınca tercih edilmesi, bilimsel alanlarda kullanılması popüler olduğunun göstergesidir (Ayvaz vd., 2016). Python 1991 yılında Guidovan Rossum tarafından çıkarılmış bir dildir. Öğrenilmesi kolay olan ve açık kaynak kod mantığını benimseyen Python dinamik bir yapıda olup çok sayıda kütüphanesi ile kullanıcılara kolaylık sağlamaktadır (Malkoç, 2012). Python programlama dilinin C ve C++ gibi dillere göre en büyük avantajı derlenmeden çalıştırılabilmesidir. Hızlı bir şekilde program geliştirilebilir. Yapısı sayesinde başkası tarafından yazılan bir programın anlaşılması diğer dillere göre daha kolaydır. Birçok işletim sistemi ve platform üzerinde çalıştırılabilir ve geliştirilebilir (Özgül, 2006). Python kolay olmasıyla birlikte güçlü bir dildir. Sahip olduğu kütüphaneler sayesinde çok fazla kod yazmadan sonuca gidilebilir. Son yıllarda kullanımı giderek artan Python finanstan fiziğe, biyolojiden web tasarımına kadar çok geniş bir alanda tercih edilmektedir. Gelişmiş kütüphaneleri sayesinde yapay öğrenme, derin öğrenme, veri bilimi gibi alanlarda oldukça fazla kullanılmaktadır (Arslan, 2019). Birçok programlama dili tarafından desteklenen nesne yönelimli programlama tekniği Python tarafından da desteklenir. Diğer dillere göre kullanımı daha kolaydır. Nesne yönelimli programlama yaklaşımı sayesinde kod tekrarı azaltılır ve kontrol kolaylaşır (Of ve Kılıçaslan, 2021). Python veri madenciliği uygulamalarında sıklıkla kullanılan bir dildir. Pandas, NumPy ve SciPy gibi kütüphaneleri kullanarak veri analizi ve işleme, TensorFlow, PyTorch ve Scikit-learn gibi kütüphanelerle yapay zeka ve makine öğrenmesi modellerinin geliştirilmesine olanak sağlar (Erden, 2021).

Python yüksek seviyeli bir dil olduğundan programcılarının donanım seviyesi ayrıntılarıyla uğraşmasını azaltır, daha soyut seviyede programlama yapmalarını sağlar. Derlenmiş dillerin aksine, yorumlanabilir bir dildir. Bu sayede hızlı prototipleme yapmaya olanak tanır. Python, GitHub ve StackOverflow gibi platformlarda en popüler programlama dillerinden biri olarak kabul edilir. Büyük bir topluluğa sahip olması sayesinde yeni

başlayanlardan deneyimli geliştiricilere kadar herkese geniş bir kaynak ve destek ağı sunar. Python ile programlama yaparken bir metin editörü bile yeterli olurken bir entegre geliştirme ortamının tercih edilmesi kullanıcılara çok daha fazla kolaylık sağlayacaktır.

Python, esnekliği, çok yönlülüğü ve kullanım kolaylığı nedeniyle, hem akademik hem de endüstriyel çevrelerde giderek daha fazla tercih edilen bir dil haline gelmiştir. Bu özellikler, onu modern yazılım geliştirme, veri bilimi, yapay zeka ve daha pek çok alanda vazgeçilmez bir araç yapar.

4. MATERİYAL ve YÖNTEM

4.1. Materyal


4.1.1. Makine öğrenmesi yöntemleriyle tahmin yapma

Bu bölümde Erzincan ilinde bulunan 106 okul için Rassal Orman (Random Forest Regression), Destek Vektör Makinesi (Support Vector Regression), Doğrusal Regresyon (Linear Regression), K-En Yakın Komşu(K Nearest Neighbour) ve Çok Katmanlı Algılayıcı (Multi Layer Perceptron) makine öğrenmesi teknikleri kullanılarak elektrik tüketim tahmininde bulunulmaya çalışılmıştır. Bu çalışmanın tüketim tahmininde bulunulacak kurumlar için stratejik planlama yapılması ve verimliliğin artırılması amacıyla önemli olduğu düşünülmektedir. Bu kurumların okul olması enerji verimliliği konularında topluma da örnek olabilir. Enerji tüketiminin etkin yönetimi, bu konuda toplumsal farkındalığın artırılmasına katkıda bulunur. Elektrik tüketimi tahminleri, okulların enerji verimliliğini artıracak iyileştirmelerin yapılmasına yardımcı olur. Bu, izolasyon iyileştirmeleri, enerji verimli aydınlatma sistemlerine geçiş veya zamanlayıcılar ve sensörlerin kullanımı gibi değişiklikleri içerebilir. Süreç verilerin toplanması, veriler üzerinde ön işlemlerin yapılması, seçilen makine öğrenmesi yöntemleriyle tahminlerin yapılması, modellerin başarılarının ölçülmesi ve sonuçların analiz edilmesi adımlarıyla ilerleyecektir.

4.1.2. Uygulamada kullanılan yazılımlar

5 farklı makine öğrenmesi yöntemiyle modeller oluşturmak, modelleri eğitmek ve sonuca ulaşmak için açık kaynak kodlu programlama dili olan python dili kullanılmıştır. Python dilini uygulamak için Şekil 4.1 'de görülen entegre geliştirme ortamı olan “jupyter notebook” programından faydalanılmıştır. Jupyter notebook çok sayıda programlama dili için destek sunar. Basit kullanıma sahiptir. Kodların blok blok çalışmasına olanak sağlar. Kodların okunup yazılmasını sağlayan not defteri görünümünde bir ara yüze sahiptir (Tuzcu, 2020). Jupyter notebook veri madenciliği için güçlü görselleştirme araçlarına sahiptir. Model geliştirme, eğitim, test etme ve model değerlendirme süreçleri için idealdir. Hem yerel makinede hem de bulut tabanlı platformlarda çalışabilir.


Yapılan kodlamaların parça parça çalıştırılıp sonucun görülmesi hatalı kodlamalara hızlı bir şekilde müdahale imkânı sağlamıştır. Bu sayede var olan kodlama hataları daha fazla büyümeden düzeltilmiştir. Kodların tamamının derlenmesine ihtiyaç olmaması zamanın da etkili kullanılmasını sağlamıştır.



Şekil 4.1. Jupyter Notebook Ara Yüzü


4.1.3. Veri setinin oluşturulması

Veri seti, makine öğrenmesi modelinin karmaşık öğrenme süreçlerini gerçekleştirebilmesi için yeterli büyüklükte olmalıdır. Bu tez çalışmasında Erzincan ili merkez ve ilçelerinde bulunan 106 okul için elektrik tüketim tahmininde bulunulmuştur. Sağlıklı bir sonuca ulaşabilmek için seçilen okulların benzer özellikler göstermesine dikkat edilmiş ve ilköğretim okulları tercih edilmiştir. 106 okulun 69 tanesi merkezde, 37 tanesi ise ilçelerde yer almaktadır. Merkezde yer alan okulların 16 tanesi anaokulu, 30 tanesi ilkokul ve 23 tanesi ise ortaokuldur. İlçelerde yer alan okulların ise 7 tanesi anaokulu, 15 tanesi ilkokul ve 15 tanesi ortaokuldur. İlçelerde yer alan okulların 9 tanesi Çayırlı, 3 tanesi İliç, 1 tanesi Kemah, 2 tanesi Otlukbeli, 3 tanesi Refahiye, 11 tanesi Tercan ve 8 tanesi Üzümlü ilçelerinde yer almaktadır. İl ve ilçeler dahilindeki okulların 23 tanesi anaokulu, 45 tanesi ilkokul ve 38 tanesi ise ortaokuldur. Veri setindeki özelliklerin tahmin edilecek değişkenle anlamlı bir ilişki içermesi gerekmektedir. Veri seti için bağımsız öznitelikler olarak okulların kapalı alan metrekaresi, sınıf sayıları, okullarda yer alan öğrenci, öğretmen ve diğer personelin toplam sayıları kullanılmıştır. Toplam 742 satır veri bulunmaktadır. Genel olarak bir okulda harcanan elektrik o okulun büyüklüğüyle doğru orantılıdır. Okulun büyüklüğü de okulun kapalı alan metrekaresi, derslik sayısı ve içerisindeki kişi sayısı ile ilişkilidir. Ancak Şekil 4.2'deki grafik incelendiğinde bu doğru orantı görülse de bazı okulların sınıf sayıları ile elektrik tüketimlerinin, bazı okulların kapalı alan metrekaresi ile elektrik tüketimlerinin, bazı okulların da içerisinde yer alan kişi sayıları ile elektrik tüketimlerinin karşılaştırmalarının diğer okullarla doğru orantılı olmadığı görülmektedir. Bu durumların çeşitli sebepleri olabilmektedir. Bazı okullarda alınan tasarruf tedbirleri elektrik tüketimini düşürdüğü gibi bazı okullarda yer alan hafta sonu kursları veya akşam kursları elektrik tüketimini artırmaktadır. Ayrıca teorik olarak, düşünülen her ilişki için ulaşılması beklenen sonuçlara gerçek uygulamalarda her zaman ulaşamadığı bir gerçektir.




Şekil 4.2. Okulların Elektrik Tüketimleri

Bağımlı değişken olan elektrik tüketimi için 2016-2022 yılları arasındaki 7 yıllık elektrik harcama verileri kullanılmıştır. 2016-2021 yılları arasındaki elektrik tüketim verileri geliştirilen makine öğrenmesi modellerinde eğitim için, 2022 yılına ait elektrik tüketim verileri ise test için kullanılmıştır. Yıllara göre okulların elektrik tüketimleri Şekil 4.3’de görülmektedir. 2019 yılında başlayan pandemi nedeniyle derslerin uzaktan yapılması sonucu okullarda yüz yüze derslerin yapılamaması sonucu elektrik tüketiminin 2019 yılında düşmeye başladığı görülmektedir. 2020 yılının büyük bir çoğunluğunda da okullarda yüz yüze eğitimin olmaması nedeniyle o yıl da elektrik tüketiminin minimum düzeyde olduğu görülmektedir. Yıllar içerisindeki toplam elektrik tüketimleri mevsimsel etkilerle de değişiklik göstermektedir. Kışın soğuk geçmesi ısınma için kullanılan doğalgaz kazanlarının daha fazla çalışmasına ve doğal olarak harcanan elektriğinde daha fazla olmasına sebep olmaktadır.



Şekil 4.3. 2016-2022 Yılları Arasında Okullardaki Elektrik Tüketimi Değişimi

Başlangıçta belirtilen yıllar arasındaki elektrik tüketim verileri aylık olarak alınmıştır. Ancak bazı aylarda okullara elektrik faturasının gelmediği sonraki aylarda faturaların toplu olarak dağıtıcı firma tarafından yollandığı görülmüştür. Bu durum tahmin esnasında yanlış sonuçlar ortaya çıkardığından yıllık elektrik tüketimleri kullanılmıştır. Çalışmada etik kurallara uyulmuş ve okul isimleri ile abone numaralarına yer verilmemiştir. Şekil 4.4’de 106 okulun her birinin 2016-2022 yılları arasındaki toplam elektrik tüketimleri grafiği görülmektedir. Veri seti içerisinde altı yılda toplam 5000 kW seviyesinde elektrik tüketimi yapan okul olduğu gibi toplam 40000 kW seviyesinde elektrik tüketimi yapan okulun olduğu görülmektedir.



Şekil 4.4. 106 Okulun 2016-2022 Yılları Arasındaki Toplam Elektrik Tüketimleri

4.1.4. Veri önışleme ve temizleme

Veri seti içerisinde eksik ve aykırı değlererin yer alması araştırma sonucunu önemli ölçüde olumsuz etkilemektedir. Makine öğrenmesi yöntemleri ile doğru sonuca ulaşabilmek için öncesinde veri seti üzerinde bazı önışlemler yapmak gerekir. Kayıp verinin az olması durumunda kayıp verinin olduğu satır komple yok sayılabilir. Kayıp veri fazla ise regresyon analizi, son gözlemi ileri taşıma, beklenti maksimizasyonu vb. yöntemler kullanılarak kayıp veriler tahmin edilerek yerine tahmin verileri eklenir (Sezgin ve Çelik, 2013). Öncelikle bu çalışma için kullanılacak veri setinde yer alan satırlar incelenmiş, eksik ve aykırı verilerin tespiti yapılmıştır. Sonrasında ise veri setine normalizasyon işlemi uygulanmıştır.

4.1.4.1. Eksik verileri silme

Okullar için gerekli olan veriler Erzincan İl Milli Eğitim Müdürlüğünden alınmıştır. Başlangıçta 125 adet okulun verisine ulaşılmıştır. Veri madenciliği uygulamalarında verilerin eksik, hatalı veya tutarsız olmaması gerekir. Veri seti, modelin gerçek dünya senaryolarına genelleştirebilmesi için uygun yapıda olmalıdır. Bahsedilen durumlar göz önünde bulundurulduğunda ve mevcut veriler incelendiğinde, elektrik tüketimleri göz önüne alındığında bazı okulların verilerinin gözle görülür şekilde ilişkisiz olduğu görülmüştür. Veriler arasındaki uyumsuzluktan ötürü 19 okul inceleme dışına alınmıştır. Kalan 106 okula ait veriler öncelikle Excel tablosu olarak oluşturulmuştur. Verilerin tamamı sayısal olduğu için verilerin nokta ve virgül ayrımları incelenip gerekli düzeltmeler yapılarak python dilinde kullanılabilir hale getirilmiştir.


4.1.4.2. Verilerin normalize edilmesi

Verilerin ölçeklendirilmesi diğer adıyla veri normalizasyonu özellikle veri seti içerisinde yer alan özniteliklerin birbirinden farklı türde veri içermesi durumunda uygulanması gereken önemli bir aşamadır (Polatgil, 2023). Veri seti içerisinde yer alan veriler farklı ölçeklerle kaydedilmişlerse bu durum veri bütünlüğünü bozar. Veri madenciliği uygulamalarında önemli bir yeri olan normalizasyon ile bu bozulmanın önüne geçilir (Tunç ve Ülger, 2016). Yapay sinir ağlarında girdi ve çıktıların ölçeklendirilmesi ağın

performansını olumlu şekilde etkilemektedir. Bu sayede verilerin dağılımı daha düzenli bir hal almaktadır. Ayrıca normalizasyon ile veri seti içerisinde yer alan yanlış verinin etkisi azaltılmaktadır. Min-max, z-skor, sigmoid, ortanca gibi veri normalizasyonu çeşitleri bulunmaktadır (Cihan vd., 2017). Tahmin çalışması için toplanan 106 okula ait verinin makine öğrenmesi yöntemleri ile kullanılabilmesi için uygun formata sahip olması gerekmektedir. Verilerin hepsi sayısal içerikten oluşmaktadır. Çalışmada 300 m² kapalı alana sahip okul bulunurken 6000 m² kapalı alana sahip okul da bulunmaktadır. Benzer olarak 4 sınıfa sahip okul bulunurken 36 sınıfa sahip okul da bulunmaktadır. Başka bir örnek olarak içerisinde 40 kişi olan okul bulunmaktayken içerisinde 600 kişi olan okul da bulunmaktadır. Birbirlerine sayısal anlamda uzak veriler bulunduğu için bu verileri organize etmek gerekmektedir. Veri seti için en uygun veri seti formunu yakalamak önemli bir gerekliliktir. Aksi durumda istenmeyen sonuçların doğması mümkündür. Bu çalışma öncelikle veriler normalize edilmeden yapılmak istendiğinde tahmin sonuçlarının gerçek sonuçlardan uzak olduğu görülmüştür. Farklı ölçeklerdeki verilerin uygun bir şekilde ölçeklendirilmesi veya normalleştirilmesi, özellikle bazı makine öğrenmesi algoritmalarında modelin daha iyi performans göstermesini sağlar. Değişkenlerin birbirlerine yakın aralıkta veriler içermesi başarı oranını artırmaktadır. Bu sebeple bağımlı ve bağımsız değişkenler içerisinde yer alan verilerin tamamı min-max scalling yöntemiyle 1 ve 2 sayıları aralığına indirgenmiştir. Normal koşullarda min-max scalling yöntemiyle veriler 0-1 aralığına indirgenir. Ancak bu durumda bazı veriler sıfır değerini alacağından bazı performans ölçütlerinin hesaplanmasında hatalı sonuçlar alınmıştır. Bu nedenle tahminlerin doğruluklarını hesaplayabilmek için veriler 1-2 aralığına indirgenmiştir.

4.2. Yöntem


Bu bölümde Rassal Orman, Destek Vektör Makinesi, K-En Yakın Komşu, Doğrusal Regresyon ve Çok Katmanlı Algılayıcı makine öğrenmesi teknikleri ile yapılan tahmin ve sonuçlara yer verilecektir. Makine öğrenmesi yöntemleriyle yapılan tahmin işleminde genel süreç Şekil 4.5’de verilen adımlarla ilerlemektedir.



Şekil 4.5. Temel Makine Öğrenmesi Süreci (Gültepe, 2019)


4.2.1. Rassal orman yöntemi ile elektrik tüketimini tahmin etme

Rassal orman, karar ağaçlarına dayalı güçlü ve esnek bir makine öğrenmesi algoritmasıdır ayrıca hem sınıflandırma hem de regresyon problemlerinde etkili sonuçlar verebilir. Bu nedenle çalışmada rassal orman yöntemine yer verilmiştir. 2016-2021 yılları arasını kapsayan eğitim setinin kullanıldığı modele rassal orman yöntemi uygulandığında elde edilen 2022 yılı elektrik tüketimi tahmini ile 2022 yılına ait gerçek elektrik tüketimi verilerinin grafiksel karşılaştırması Şekil 4.6’da verilmiştir.



Şekil 4.6. Rassal Orman Yöntemi ile Tahminleme


Rassal orman yöntemi kolay uygulanabilir yöntemlerden bir tanesi olduğu için tahminleme yaparken hiperparametreler için optimum değerler kullanılmıştır. Algoritmanın oluşturduğu ağaç sayısı yani “estimator” değeri 100 olarak belirlenmiştir. Model çıkışını çoğaltılamaz hale getiren “random state” değeri ise 42 olarak belirlenmiştir. Şekil 4.7’de rassal orman modelinin ilk karar ağacının düğüm yapısından örnek bir kısım görülmektedir.



Şekil 4.7. Örnek Düğüm Yapısı

4.2.2. Destek vektör makinesi yöntemi ile elektrik tüketimini tahmin etme


Elektrik tüketim tahmininde kullanılabilecek yöntemlerden bir tanesi de destek vektör makineleridir. DVM, veriler arasındaki en iyi ayrım sınırını (karar sınırı) bulmak için tasarlanmıştır. Bu, elektrik tüketimi gibi karmaşık veri setlerinde, farklı sınıflar veya düzeyler arasındaki ayrımı belirlemek için kullanılabilir. DVM büyük veri setlerinde eğitim süreci uzun sürebilir. Ancak çalışmadaki veri setinin büyük olmaması içi DVM için bir avantajdır. Oluşturulan model DVM yöntemiyle eğitilip tahmin çalışması yapıldığında elde edilen sonuçlarla gerçek verilerin karşılaştırılması Şekil 4.8’de verilmiştir.




Şekil 4.8. Destek Vektör Makinesi Yöntemi ile Tahminleme

DVM, çekirdek hilesi sayesinde doğrusal olmayan ilişkileri modelleyebilir. Bu, elektrik tüketimi gibi karmaşık ve doğrusal olmayan ilişkilere sahip veriler için önemlidir. Algoritmada çekirdek olarak “rbf” yöntemi kullanılmıştır. Bu çekirdek yöntemiyle sınıflama yapılırken her bir noktanın belirli bir noktaya ne kadar benzediği normal dağılımla belirlenir ve sınıf belirlenir. Dağılımın belirlenmesinde kullanılan “gamma” parametresinin ise modelde yer alan öznitelik sayısına göre belirlenmesi sağlanmıştır. Bu sebeple “gamma” parametresi “auto” olarak belirlenmiştir. Durdurma kriteri toleransı ise varsayılan olarak ayarlanmıştır. DVM ile tahmin yaparken bağımlı değişken ile bağımsız


değişkenler arasındaki ilişkiler gösterilmeye çalışılmıştır. Şekil 4.9’ da kapalı alan ile elektrik tüketimi arasındaki ilişkiye, Şekil 4.10’da kişi sayısı ile elektrik tüketimi arasındaki ilişkiye ve Şekil 4.11’de sınıf sayısı ile elektrik tüketimi arasındaki ilişki gösterilmiştir.



Şekil 4.9. Kapalı Alan ve Elektrik Tüketimi Arasındaki İlişki




Şekil 4.10. Kişi Sayısı ve Elektrik Tüketimi Arasındaki İlişki



Şekil 4.11. Sınıf Sayısı ve Elektrik Tüketimi Arasındaki İlişki


4.2.3. K-en yakın komşu yöntemi ile elektrik tüketimini tahmin etme

Çalışmada tercih edilen diğer yöntemlerden bir tanesi de anlaşılması ve çalışması basit olan KNN yöntemidir. KNN, özellikler arasındaki mesafeye dayalı olduğundan, tüm özelliklerin uygun şekilde ölçeklenmesi gerekmektedir. Veri seti normalize edildiğinden KNN yöntemi çalışma için uygun bir yöntemdir. Model K-En yakın komşu yöntemiyle eğitildiğinde elde edilen tahminlerin gerçek verilerle karşılaştırılması şekil 4.12’de verilmiştir. “k_neighbors” parametresi modelde kullanılan en önemli parametredir. K değeri nesnenin hangi sınıfa dahil olacağını belirlemek için yakınındaki kaç sınıfa bakılacağını belirler. Model bu yöntemle eğitilirken rastgele değerler verilmiş ve son olarak k değeri 3 olarak belirlenmiştir.



Şekil 4.12. K-En Yakın Komşu Yöntemi ile Tahminleme


Gerçek ve tahmin edilen değerler arasındaki ilişkiyi daha iyi görebilmek için Şekil 4.13’de regresyon çizgisi grafiğine yer verilmiştir. Turuncu kesikli çizgi regresyon çizgisini, çizginin altında kalan değerler gerçek değerleri, çizginin üstünde kalan değerler ise tahmin değerlerini göstermektedir. Regresyon çizgisi düz olduğu için KNN modeline göre bağımlı değişkenle bağımsız değişkenler arasında doğrusal bir ilişkinin olduğu görülmektedir.



Şekil 4.13. Gerçek ve Tahmin Edilen Değerlerin Regresyon Çizgisi


4.2.4. Doğrusal regresyon yöntemi ile elektrik tüketimini tahmin etme

Bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki olduğunda doğrusal regresyon yöntemiyle etkili sonuçlar alınabilir. Çalışmada yer alan veri seti içerisindeki değişkenler arasında çoğunlukla doğrusal bir ilişki ve karmaşık ilişkiler de mevcut olmasına rağmen bu yöntem kullanılarak sonuç alınmaya çalışılmıştır. Ayrıca veri setinde çok fazla özellik olmaması da bu modelin tercih edilme nedenlerinden biridir. Doğrusal regresyon yöntemi ile elde edilen sonuçların gerçek verilerle karşılaştırılması Şekil 4.14’de verilmiştir.



Şekil 4.14. Doğrusal Regresyon Yöntemi ile Tahminleme

Gerçek ve tahmin edilen veriler arasındaki hataları gösteren grafiğe Şekil 4.15’de yer verilmiştir. 106 okul için gerçek ve tahmin verilerinin yer aldığı grafik incelendiğinde hata değerlerine göre frekanslar görülmektedir.



Şekil 4.15. Hata Dağılımı Grafiği


4.2.5. Çok katmanlı algılayıcı yöntemi ile elektrik tüketimini tahmin etme

Yapay sinir ağı yöntemlerinden biri olan çok katmanlı algılayıcı yöntemi elektrik tüketimlerini tahmin etmek için yaygın olarak kullanılan yöntemlerden biridir. Problemin türü itibarıyla relu aktivasyon fonksiyonu tercih edilmiştir. Relu popüler bir fonksiyondur. Doğrusal olmayan problemlerde tercih edilir. Ayrıca gizli katmanlarda tercih edilir. Veri seti içerisinde yer alan bağımlı ve bağımsız değişkenler arasında her ne kadar da teoride doğrusal bir ilişki olduğu düşünülse de uygulama kısmında öyle olmadığı görülmektedir. Bu sebeple relu aktivasyon fonksiyonu giriş katmanında ve gizli katmanlarda tercih edilmiştir. Çıkış katmanında ise tek bir değişken olduğundan yani tek bir sınıf olduğundan “lineer” aktivasyon fonksiyonu kullanılmıştır.

Yapay sinir ağı modelini eğitmek için popüler optimizasyon algoritmalarından biri olan Adaptive Moment Estimation (Adam) optimizasyonu kullanılmıştır. Bu öğrenme Stochastic Gradient Descent (SGD) yöntemine göre daha hızlı ve etkili bir şekilde optimum öğrenme değerlerine ulaşır. Ayrıca varsayılan parametreleriyle etkin sonuçlar elde edilir (Agahian, 2022). İçerisinde yer alan önemli parametrelerden biri “learning rate” yani öğrenme oranıdır. Öğrenme oranı, model ağırlıklarının her güncelleme adımında ne kadar değiştirileceğini belirler. Yani, modelin öğrenme hızını kontrol eder.

Çok yüksek bir öğrenme oranı, modelin en iyi çözüme hızla yaklaşmasına neden olabilir. Ancak aynı zamanda en iyi çözümü aşmasına veya dalgalanmalara yol açabilir. Çok düşük bir öğrenme oranı, modelin en iyi çözüme çok yavaş yaklaşmasına veya yerel minimumlarda takılıp kalmasına neden olabilir (Thota, 2013). “Adam” optimizasyon algoritması içerisinde “learning rate” değeri varsayılan parametre değeriyle yer alır.

Epoch yani eğitim tur sayısının belirlenmesi, bir yapay sinir ağı modelini eğitirken önemli bir karardır. Eğitim tur sayısı, tüm eğitim veri setinin, ağ üzerinden ileri ve geri yayılım işlemlerinden tam olarak bir kez geçirilmesi anlamına gelir. Eğitim tur değerini belirleme yöntemlerinden biri kayıp değeri grafiğinin incelenmesidir. Bir modelde mümkünse kayıpların sıfır olması istenir. Bir modeli eğitmenin amacı ortalama olarak düşük kayıp elde etmektir (Kıvrak vd. 2021). Şekil 4.16 incelendiğinde 250 eğitimden sonra modelde kayıpların olmaya başladığı görülmektedir. Bu sebeple eğitim tur sayısı 250 olarak belirlenmiştir.



Şekil 4.16. Eğitim Kaybı Grafiği

Diğer önemli unsurlardan biri de katman sayısı ve katmanlardaki nöron sayısının belirlenmesidir. Bu durum yapay sinir ağları tasarımında kritik öneme sahip olan karmaşık bir süreçtir. Bu kararlar çeşitli faktörlere bağlıdır ve genellikle deneme yanılma yoluyla en uygun yapıya ulaşılır (Akkaya, 2007). Model oluşturulurken çok sayıda

deneme yapılmıştır. Tek gizli katman veya iki gizli katman kullanılmış ve katmanlardaki nöron sayıları değiştirilerek denemeler yapılmıştır. Tablo 4.1’de yapılan denemelerden 10 tanesine yer verilmiştir. Her denemeden sonra model başarısı için MAPE değeri incelenmiştir. Bu denemeler sonrasında en başarılı sonuca 2 gizli katmanlı yapı için giriş katmanında 64 nöron, birinci gizli katmanda 32 nöron ve ikinci gizli katmanda 16 nöron denemesiyle ulaşılmıştır.

Tablo 4.1. Katman ve Katmanlardaki Nöron Sayılarına Göre MAPE Değerleri

Giriş Katmanı	1. Gizli Katman	2.Gizli Katman	Çıkış Katmanı	MAPE
12	8	-	1	4.03
12	8	4	1	5.54
8	4	-	1	5.01
8	4	2	1	4.94
7	3	-	1	4.41
64	32	-	1	3.74
64	32	16	1	2.69
32	16	-	1	4.35
16	8	-	1	4.29
16	8	4	1	4.83


Katman sayıları belirlendikten sonra yapılan diğer işlem ise katman çıkışlarının hesaplanabilmesi için transfer fonksiyonlarının belirlenmesidir. Transfer fonksiyonları ile katmanların ağırlıkları ile girdi değerleri arasındaki ilişki ifade edilir. Doğru transfer fonksiyonun belirlenmesi tahmin başarısını önemli ölçüde etkilemektedir. Her bir katman için çok sayıda transfer fonksiyonu denemesi yapılmıştır. MAPE değerine bakıldığında en başarılı sonuca giriş ve gizli katmanlarda “Relu” fonksiyonu ve çıkış katmanında ise “Linear” fonksiyonunun kullanılmasıyla ulaşılmıştır. Tablo 4.2’de yapılan denemelerin bazılarına yer verilmiştir.

Tablo 4.2. Katmanlardaki Transfer Fonksiyonlarına Göre MAPE Değerleri


Giriş Katmanı	1.Gizli Katman	2.Gizli Katman	Çıkış Katmanı	MLP
Relu	Relu	Relu	Sigmoid	16.499
Relu	Sigmoid	Sigmoid	Linear	4.798
Sigmoid	Sigmoid	Sigmoid	Linear	4.752
Sigmoid	Relu	Relu	Linear	3.2634
Tanh	Relu	Relu	Linear	3.880
Tanh	Relu	Sigmoid	Linear	3.0179
Tanh	Sigmoid	Relu	Tanh	23.293
Relu	Tanh	Sigmoid	Linear	4.635
Sigmoid	Relu	Tanh	Linear	6.569
Relu	Relu	Relu	Linear	2.695

Son işlem olarak “validation split” değeri belirlenmiştir. Bu parametre ile eğitim setinin bir kısmı modelin eğitimi için kullanılırken, geri kalan kısmı ise doğrulama için kullanılır. Bu parametre 0.2 olarak belirlenerek eğitim setinin %20’sinin doğrulama yapılması için kullanımı sağlanmıştır.


Tüm ayarlamalar yapılarak model oluşturulduktan sonra tahmin verileriyle gerçek verilerin karşılaştırılmasına Şekil 4.17’de yer verilmiştir.

**Şekil 4.17.** Çok Katmanlı Algılayıcı Yöntemi ile Tahminleme

Geliştirilen model için örnek ağırlık ve bias grafiklerine yer verilmiştir. Şekil 4.18 de yer alan ağırlık grafiği birinci gizli katmanda yer alan 60. nöronun ikinci gizli katmanda yer alan 32 nöronun her birine yapılan bağlantıyı gösterir. Şekil 4.19'da yer alan bias grafiği ise birinci gizli katmanda yer alan 36. nöronun aktivasyon fonksiyonuna eklenen değeri ifade eder. Ağ, girişleri alır ve bu parametreleri kullanarak çıkış üretir.



Şekil 4.18. Ağırlık Grafiği



Şekil 4.19. Bias Grafiği


5. BULGULAR

Tahmin sonuçlarının gerçek değerlere ne kadar yakın olduğunu görebilmek için MAPE, MAE, MSE ve RMSE hata metrikleri kullanılmıştır. Tablo 2’de 106 okul için yapılan elektrik tüketim tahmininin tüm modeller için performans değerlendirilmeleri verilmiştir. Performans metriklerinde ne kadar düşük değer elde edilirse tahmin başarısı o kadar yüksek olacaktır. Tablo incelendiğinde çok katmanlı algılayıcı yöntemi ile yapılan tahminin başarısının diğer modellere göre daha yüksek olduğu görülmektedir. MAPE değerinin % 10’un altında olması tahmin başarısının yüksek olduğunu gösterir (Tekin ve Patır, 2023). MAPE değerinin %10’un altında olması “çok iyi”, %10 ile % 20 arasında olması “iyi”, % 20 ile % 50 arasında olması “makul”, % 50’nin üzerinde olması ise “kötü” olarak nitelendirilir (Aslay, 2013). Tüm modellerde MAPE değeri 10’un altındadır. Bu durum tüm modellerde başarılı sonuçlar alındığını gösterir. MAE, MSE ve RMSE değerleri değerlendirilmek istenirse sonuçlar sıfıra ne kadar yaklaşırsa tahmin başarısı o kadar yüksektir değerlendirmesi yapılır. Tüm modeller içinden de çok katmanlı algılayıcı ile yapılan tahminde MAPE değerinin 2.695 olduğu, MSE, MAE ve RMSE değerlerinin sıfıra daha yakın olduğu görülmektedir. Bu sonuçlarla, sıralamaya bakıldığında en başarılı tahminin 2.695 MAPE değeriyle çok katmanlı algılayıcı yöntemi ile yapıldığı anlaşılmaktadır. Çalışmada kullanılan diğer yöntemlerin performansları incelendiğinde performansı en düşük yöntemin 4.903 MAPE değeriyle destek vektör makinesi yöntemi olduğu görülmektedir. Eğer bağımlı bağımsız değişkenler arasında tam olarak doğrusal bir ilişki olsaydı performans sıralamasında doğrusal regresyonun birinci sırada olması gerekirdi. 3.613 MAPE değerine bakıldığında bu yöntemin performans olarak üçüncü sırada olduğu görülmektedir. MAPE değerlerinin tüm yöntemler için 10’un altında olması bu çalışmada tercih edilen yöntemlerin bu çalışmada kullanılabilir olduğunu göstermektedir.

Tablo 5.1. Model Performanslarının Değerlendirilmesi

	MAPE	RMSE	MSE	MAE
Rassal Orman	3.333	0.056	0.003	0.042
Destek Vektör Makinesi	4.903	0.068	0.004	0.058
K-En Yakın Komşu	3.728	0.061	0.003	0.046
Doğrusal Regresyon	3.613	0.053	0.002	0.043
Çok Katmanlı Algılayıcı	2.695	0.048	0.002	0.035

Veri seti içerisinde yer alan 106 okuldan rasgele seçilen 10 okul için yapılan tahminin başarısı Şekil 5.1’de verilmiştir. Şekilde önemli bir performans metriği olan MAPE’nin çalışmada kullanılan makine öğrenmesi yöntemleriyle elde edilen tahmin sonuçlarına göre karşılaştırmaları yapılmıştır.



Şekil 5.1. Modellerin MAPE Değerleri

6. SONUÇ

Elektrik ikincil enerji kaynağıdır ve birincil enerji kaynaklarının dönüşümünden elde edilir. Elektrik depolanamadığından üretildiğinde tüketilmelidir. Bu nedenle gelecekte ne kadar elektrik tüketimi yapılacağına önceden tahmin edilmesi gelecek adına yapılacak planlamalar açısından son derece önemlidir. Baltaş ve Akbay (2021) çalışmalarında olduğu gibi makine öğrenmesi yöntemleriyle geleceğe yönelik tahminlerde bulunabilmek elektrik talebi noktasında da bizlere yardımcı olur. İsmiç (2015) çalışmasında belirttiği gibi enerji bir ülkenin gelişmişlik düzeyine etki ettiği gibi o ülkenin uluslararası politikasına da yön verir. Bu nedenle enerjiyle ekonomi arasında da bir ilişki söz konusudur. En önemli enerji kaynaklarından biri olan elektrik enerjisi tüketimi toplumun refah seviyesi üzerinde de önemli bir göstergedir. Enerji yönetimi bir ülkedeki enerji kaynaklarının verimli şekilde kullanılmasını hedefler. Bir ülkenin kendi kendine yetebilir durumda olması amaçlanır. Bu çalışmada olduğu gibi Şengöz (2021) kendi çalışmasında geleceğe yönelik elektrik tüketim tahmininde bulunmuştur. Yıldırım (2021) çalışmasında yapay sinir ağı, destek vektör makinesi ve karar ağaçlarıyla elektrik tüketimini tahmin etmeye çalışmış ve RMSE ölçütüne bakarak en iyi sonucun yapay sinir ağıyla elde edildiğini söylemiştir. Bu çalışmada da RMSE ölçütü kriter olarak alındığında en iyi sonucun yapay sinir ağı yöntemi olan çok katmanlı algılayıcı tekniğiyle alındığı görülmüştür. Yine Öksüz (2019) yapmış olduğu çalışmada yapay sinir ağlarıyla elektrik tüketim tahmininde bulunup yaklaşık % 10 MAPE değeriyle iyi ve doğru bir sonuç elde ettiğini ifade etmiştir. Bu çalışmada yapay sinir ağı ile elde edilen % 2.69 MAPE değeri tahmin sonucunun çok iyi olduğunu göstermektedir.

Elektrik tüketimi tahmini konulu çalışmalar incelendiğinde çoğunlukla yapay sinir ağlarının kullanıldığı görülmüştür. Bu çalışmada da yapay sinir ağı yöntemi olan çok katmanlı algılayıcı tekniği kullanılmıştır. Özellikle bu teknikteki farklı parametreler çok defa değiştirilerek tahmin çalışmaları yapılmıştır. Bununla birlikte çok katmanlı algılayıcı yönteminden farklı olarak 4 adet makine öğrenmesi yöntemiyle de sonuçlar alınmıştır. Modellerin başarı performanslarına bakıldığında ise 2.695 MAPE, 0.048 RMSE, 0.002 MSE ve 0.035 MAE değerleriyle çok katmanlı algılayıcı ile yapılan tahminlerin diğer modellerle yapılan tahminlere göre daha başarılı olduğu görülmüştür. Böylece modellerinde başarı kıyaslaması yapılmıştır.

Gelişmişlik düzeyinin artmasıyla harcamalarında arttığı ülkemizde tasarruf planlamaları yapılmaktadır. Tasarrufun hedeflendiği alanlardan biri de kamu binalarıdır. Okullarımızda kamu binaları içerisinde önemli bir yer oluşturmaktadır. Yapılan tasarruf planlamalarının içerisinde elektrik harcamaları da önemli bir yer edinmektedir. Mevcut elektrik harcamalarının bilinmesiyle geleceğe yönelik tahminde bulunma tasarruf hedeflerine ulaşmada çizilecek yol haritasında çok önemli bir yere sahiptir. Bu çalışmanın okullarımıza yol gösterici nitelikte olacağı düşünülmektedir. Özellikle İl Milli Eğitim Müdürlükleri bünyesinde kurulan Enerji Yönetim Birimleri benzer çalışmalarla kendi illerindeki okulların gelecekteki elektrik tüketimlerini tahmin edebileceklerdir. Böylece mevcut tüketimlerin durumuna göre hedef yılı gelmeden önceden tedbirler alarak belirlenen tasarruflara daha kolay ulaşabileceklerdir.

Milli Eğitime bağlı resmi okulların elektrik faturalarını ödemek için kendilerine ait bir bütçeleri bulunmamaktadır. Her fatura döneminde Bakanlıktan faturalar için ödenek istenmekte ve ödemeler bu şekilde yapılmaktadır. Bu çalışmanın ülke genelinde yapılması enerji maliyetlerini optimize etmek ve bütçeleme süreçlerinde daha doğru tahminler yapmak için faydalı olacağı düşünülmektedir.

Veri madenciliği uygulamalarında en önemli unsurlarından biri hiç şüphesiz ki çok sayıda doğru ve güvenilir veridir. Bu çalışmada doğru ve güvenilir verinin önemi görülmüştür. 2016 yılı öncesindeki birçok okulun elektrik tüketimi verisine ulaşılamadığı için çalışma 2016-2022 yılları arasını kapsamıştır. 2016-2022 yılları arasında da bazı okulların verilerinde tutarsızlık görüldüğü için çalışmanın kapsamı 106 okulla sınırlandırılmıştır. Önceki yılların verilerine ve daha fazla okulun verisine ulaşılabilseydi daha başarılı sonuçlara ulaşılabilirdi düşünülmektedir. Gelecekte yapılacak benzer çalışmalarda bu hususlar üzerinde durulup önlemler alınması daha etkili sonuçlar elde edilmesini sağlayacaktır.

Sonuç olarak bu çalışmada enerji verimliliği kapsamında Milli Eğitime bağlı okullarda elektrik tüketimi tahmini yapılarak literatüre yeni bir bakış açısı sunulmuştur.

KAYNAKLAR

- Aalen, O. O. (1989). "A Linear Regression Model For The Analysis of Life Times", *Statistics in Medicine*, 8(8), 907-925.
- Acı, M., Avcı, M. ve Acı, Ç. (2017). "Destek Vektör Regresyonu Yöntemiyle Karbon Nanotüp Benzetim Süresinin Kısaltılması", *Journal of The Faculty Of Engineering and Architecture of Gazi University*, 32(3), 901-907.
- Acıkkar, M. ve Sivrikaya, O. (2020). "Yıkanmış Türk Linyit Kömürlerinin Üst Isıl Değerinin Destek Vektör Regresyonu ile Tahmini", *Avrupa Bilim ve Teknoloji Dergisi*, (18), 16-24.
- Agahian, S. and Akan, T. (2022). "Battle Royale Optimizer For Training Multi-layer Perceptron", *Evolving Systems*, 13(4), 563-575.
- Agyare, O. R., Odoi, B. and Asamoah, M. (2021). "Electricity Consumption Forecast for Tarkwa Using Autoregressive Integrated Moving Average and Adaptive Neuro Fuzzy Inference System", *Serbian Journal of Electrical Engineering*, 18(1), 75-94.
- Ağyar, Z. (2015). "Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama", *Mühendis ve Makine*, 56(662), 22-23.
- Akalın, B. ve Veranyurt, Ü. (2021). "Sağlık Hizmetleri ve Yönetiminde Yapay Zekâ", *Acta Infologica*, 5(1), 231-240.
- Akanesen.(2023)."Yapay Sinir Ağının Ana Öğeleri".
<https://www.akanesen.com/2017/09/yapay-sinir-aginn-ana-ogeleri.html>,
Son Erişim Tarihi:10.11.2023
- Akkaya, G. (2007). "Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları", *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, Erzurum, 38(2), 195-202.
- Akkurt, A. (2005). "Yapay Sinir Ağları ve Türkiye Elektrik Tüketimi Tahmin Modeli", Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Alpaydin, E. (2020). "Introduction to Machine Learning", *Massachussets Institute of Technology*, Cambridge:The MIT Press.
- Alptuğ Yavaş, M. (2018). "İşletmelerde Enerji Eerimliliği ve Konya Sanayi İşletmeleri Üzerine Bir Araştırma/A Research on Energy Efficiency in Enterprises and Industrial Enterprises in Konya", *KTO Karatay Üniversitesi*, Konya.
- Altun, Ö. (2022). "Yapay Zekâ Yöntemleriyle Hazine Taşınmazlarının Değerlemesi: Yapay Sinir Ağları ile Kamu Konutları Üzerine Bir Uygulama", *Türkiye Arazi Yönetimi Dergisi*, 4(2), 62-73.

- Amber, K. P., Ahmad, R., Aslam, M. W., Kousar, A., Usman, M. and Khan, M. S. (2018). "Intelligent Techniques for Forecasting Electricity Consumption of Buildings", *Energy*, 157, 886-893.
- Arı, A. ve Berberler, M. E. (2017). "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı", *Acta Infologica*, 1(2), 55-73.
- Arslan, İ. (2019). "Python ile Veri Bilimi." *Pusulula*, 347-397.
- Arslan, K. (2020). "Eğitimde Yapay Zekâ ve Uygulamaları", *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Aslay, F. (2013). "Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları ile Toprak Sıcaklığının Tahmini", *Doktora Tezi, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü*, Erzurum.
- Atalay, M. (2013). "Makine Öğrenme Yöntemleri Yardımıyla Tüketim İstatistiklerine Göre Talep Tahmini", *Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Atalay, M. ve Çelik, E. (2017). "Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları - Artificial Intelligence and Machine Learning Applications in Big Data Analysis", *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ataseven, B. (2013). "Yapay Sinir Ağları ile Öngörü Modellemesi", *Öneri Dergisi*, 10(39), 101-115.
- Aydın, C. (2018). "Makine Öğrenmesi Algoritmaları Kullanılarak İtfaiye İstasyonu İhtiyacının Sınıflandırılması", *Avrupa Bilim ve Teknoloji Dergisi*, (14), 169-175.
- Aydın, S. ve Özkul, A. E. (2015). "Veri Madenciliği ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama", *Journal of Research in Education and Teaching*, 4(3), 36-44.
- Ayhan, S. ve Erdoğan, Ş. (2014). "Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi", *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Ayvaz, U., Çoban, A., Gürüler, H. ve Peker, M. (2016). "Python Dilinin Öznitelikleri, Programlama Eğitiminde ve Yazılım Dünyasındaki Yeri", *Muğla Sıtkı Koçman Üniversitesi Bilişim Sistemleri Mühendisliği Bölümü*, Muğla.
- Aydın, Ö. (2019). "Binalarda Enerji Verimliliği Kapsamında Yapılan Projelerin Değerlendirilmesi: Türkiye örneği", *Mimarlık ve Yaşam*, 4(1), 55-68.

- Azadeh, A., Ghaderi, S. F. and Sohrabkhani, S. (2008). "Annual Electricity Consumption Forecasting by Neural Network in High Energy Consuming Industrial Sectors", *Energy Conversion and management*, 49(8), 2272-2278.
- Baltaş, M. ve Akbay, C. (2021). "Akdeniz Elektrik Dağıtım Bölgesi (Antalya-Isparta-Burdur) Elektrik Tüketim Talep Tahmini", *Journal of Management and Economics Research*, 19(2), 222-238.
- Başoğlu, B. ve Bulut, M. (2017). "Kısa Dönem Elektrik Talep Tahminleri İçin Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi", *Journal of the Faculty of Engineering & Architecture of Gazi University*, 32(2).
- Baydemir, M. B. (2014). "Lojistik Regresyon Analizi Üzerine Bir İnceleme", Yüksek Lisans Tezi, *İnönü Üniversitesi Sosyal Bilimler Enstitüsü*, Malatya.
- Bayır, F. (2006). "Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama" Yayınlanmamış Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul.
- Baysal, H. ve Daşdemir, İ. (2023). "Fen Bilimleri Öğretmenlerinin Yenilenebilir Enerji Kaynakları Hakkındaki Farkındalık Düzeylerinin Belirlenmesi", *Milli Eğitim Dergisi*, 52(237), 255-278.
- Bedi, P. P. S., Aggarwal, H., Narula, S. and Jain, S. (2022). "Increasing the Versatility of LeakyReLU Using a Nonlinear Function", *In Advanced Machine Intelligence and Signal Processing*, (pp. 433-442), Singapore: Springer Nature Singapore.
- Bianco, V., Manca, O. and Nardini, S. (2009). "Electricity Consumption Forecasting in Italy Using Linear Regression Models", *Energy*, 34(9), 1413-1421.
- Bicil, İ. M. (2015). "Elektrik Piyasasında Fiyatlandırma ve Türkiye Elektrik Piyasasında Fiyat Tahmini", Doktora Tezi, *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü*, Balıkesir.
- Bilgili, M. (2009). "Türkiye'nin Net Elektrik Tüketiminin Tahmini", *İst Bilimi ve Tekniği Dergisi*, 29(2), 89-98.
- Boltürk, E. (2013). "Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması", Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Bostrom, N. (2016). "The Control Problem. Excerpts from Super Intelligence: Paths, Dangers, Strategies", *Science Fiction and Philosophy: From Time Travel to Super Intelligence*, 308-330.
- Botman, L., Soenen, J., Theodorakos, K., Yurtman, A., Bekker, J., Vanthournout, K. and Lago, J. (2022). "A Scalable Ensemble Approach to Forecast the Electricity Consumption of Households", *IEEE Transactions on Smart Grid*, 14(1), 757-768.

- BP.(2022). “Statistical Review of World Energy 2022”. *1 S tJames’s Square London, SW1Y 4PD UK*.
- Brownlee, J. (2018). “What is The Difference Between a Batch and an Epoch in a Neural Network”, *Machine Learning Mastery*, 20.
- Bulut, F. (2016). “Çok Katmanlı Algılayıcılar ile Doğru Meslek Tercihi”,*Anadolu University Journal of Science and Technology A-Applied Sciences and Engineering*, 17(1), 97-109.
- Büyükkuşal, M. Ç. ve Öz, İ. İ. (2016). “Çoklu Doğrusal Bağlantı Varlığında En Küçük Karelere Alternatif Yaklaşım: Ridge Regresyon”, *Düzce Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 6(2), 110-114.
- Chen, L., Chen, P. ve Lin, Z. (2020). “Artificial Intelligence in Education: A Review”, *Ieee Access*, 8, 75264-75278.
- Ceylan, G. (2004). “Yapay Sinir Ağları ile Kısa Dönem Yük Tahmini”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Cihan, P., Kalıpsız, O. ve Gökçe, E. (2017). “Hayvan Hastalığı Teşhisinde Normalizasyon Tekniklerinin Yapay Sinir Ağı ve Özellik Seçim Performansına Etkisi”, *Electronic Turkish Studies*, 12(11).
- Coşar, M. ve Deniz, E. (2021). “Makine Öğrenimi Algoritmaları Kullanarak Kalp Hastalıklarının Tespit Edilmesi”, *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1112-1116.
- CSB.(2023).”Çevre Şehircilik ve İklim Değişikliği Bakanlığı”,
<https://cevreselgostergeler.csb.gov.tr/sektorlere-gore-nihai-enerji-tuketimi-i-85804>,
Son Erişim Tarihi:10.11.2023
- Çakı, E. E. ve Bayram, F. (2022). “CNN-FL Modeli ile Pnömoni Tespitinin Aktivasyon Fonksiyonlarına Göre Karşılaştırılması”, *3rd International Conference on Applied Engineering and Natural Sciences*, Konya
- Çatal, Ç. and Özyılmaz, L. (2005). “Multiple Myeloma Gene Expression Data Analysis with Multi Layer Perceptrons”, *National Conference on Biomedical Engineering*, Bogazici University, İstanbul.
- Çayır, A., Yenidoğan, İ. ve Dağ, H. (2018). “Konutların Günlük Elektrik Güç Tüketimi Tahmini İçin Uygun Model Seçimi”, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 30(3), 15-21.
- Çelik, S. (2018). “Büyük Veri ve İstatistikteki Uygulamaları”, Doktora Tezi, *Uludağ Üniversitesi Sosyal Bilimler Enstitüsü*, Bursa

- Çelik, Ş. (2022). “Yapay Sinir Ağlarının Farklı Aktivasyon Fonksiyonlarında Uygulaması: Türkiye’de Ördek Popülasyonu Öngörüsü”, *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(2), 800-811.
- Demirel, Ö., Kakıllı, A. ve Tektaş, M. (2010). “Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(3).
- Demirezen, S. ve Çetin, M. (2021). “Rassal Orman Regresyonu ve Destek Vektör Regresyonu ile Piyasa Takas Fiyatının Tahmini”, *Nicel Bilimler Dergisi*, 3(1), 1-15.
- Demirhan, T. (2015). “Makine Öğrenmesi Algoritmalarının Karmaşıklık ve Doygunluk Analizinin Bir Veri Kümesi Üzerinde Gerçekleştirilmesi”, Doktora Tezi, *Trakya Üniversitesi Fen Bilimleri Enstitüsü*, Edirne.
- Devreyakan.(2023). “Performans Metrikleri”,
<https://devreyakan.com/performans-metrikleri/>,
Son Erişim Tarihi:15.11.2023.
- Diri, B. (2014). “Makine Öğrenmesine Giriş.”
<https://www.ce.yildiz.edu.tr/personal/banud/file/2634/Makine+Ogrenmesi-ML-10.pdf>.
Son Erişim Tarihi: 17.11.2023.
- Doğan, H. ve Yılankıran, N. (2015). “Türkiye’nin Enerji Verimliliği Potansiyeli ve Projeksiyonu”, *Gazi University Journal of Science Part C: Design and Technology*, 3(1), 375-384.
- Efe, A. (2021). “Yapay Zekâ Odaklı Siber Risk ve Güvenlik Yönetimi”, *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 5(2), 144-165.
- Eke, E. U. ve Ayrancı, E. (2018).”Türkiye’de Elektrik Enerjisi Sektörünün Enerji Yoksulluğu Açısından Değerlendirilmesi”, *Politik Ekonomik Kuram*, 2(2), 109-129.
- Ekinci, F. (2019). “YSA ve ANFIS Tekniklerine Dayalı Enerji Tüketim Tahmin Yöntemlerinin Karşılaştırılması”, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(3), 1029-1044.
- Er, Y. ve Karaca, E. (2021). “Farklı Yöntemlerle Karadeniz Bölgesinin Aylık Elektrik Tüketim Tahmini”, *Sürdürülebilirlik İçin Akademik Araştırmalar-1*, 137-147
- Erbaş, Ü. (2005). “Yapay Sinir Ağları ve Uygulama Alanları”, Doktora Tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul.
- Ercan, U., Irmak, S., Çevik, K. K. ve Canbazoglu, E. (2020). “Yapay Sinir Ağları Kullanılarak Konutlarda Elektrik Tüketimi Düzeylerinin Tahmin Edilmesi”, *Sosyoekonomi*, 28(46), 173-186.

- Erden, C. (2021). "Python ile Veri Madenciliği", *Kodlab Yayın Dağıtım Yazılım LTD. ŞTİ.*, İstanbul.
- Ergün, O. (2023). "Makine Öğrenmesi Algoritmaları İle Müşteri Segmentasyonu ve Hepsiburada E-Ticaret Platformu Üzerine bir Uygulama", Doktora Tezi, *Uludağ Üniversitesi Sosyal Bilimler Enstitüsü*, Bursa.
- Ergün, S. ve Polat, M. A. (2015). "OECD Ülkelerinde CO2 Emisyonu, Elektrik Tüketimi ve Büyüme İlişkisi", *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (45), 115-141.
- Erol, B., Cantekin, R., Kartal, S., Hacıoğlu, R., Görmüş, K. S., Kutoğlu, Ş. H. ve Leblebicioğlu, K. (2021). "İnsansız Sualtı Aracı Hareketinin Kalman Filtre İle Kestirimi ve Makine Öğrenmesi ile İyileştirilmesi", *International Journal of Advances in Engineering and Pure Sciences*, 33, 67-77.
- Ersoy, E. ve Karal, Ö. (2012). "Yapay Sinir Ağları ve İnsan Beyni", *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Eskici, H. B. ve Koçak, N. A. (2018). "SAS Enterprise Miner ile Metin Madenciliği", *Pusula 20 Teknoloji ve Yayıncılık A.Ş.*, İstanbul.
- Ever, D. ve Demircioğlu, E. N. (2022). "Yapay Zekâ Teknolojilerinin Kalite Maliyetleri Üzerine Etkisi", *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 31(1), 59-72.
- ETKB 1.(2023). "Enerji ve Tabii Kaynaklar Bakanlığı", <https://enerji.gov.tr/enerji-isleri-genel-mudurlugu-denge-tablolari>, Son Erişim Tarihi: 10.11.2023
- ETKB 2.(2023). "Enerji ve Tabii Kaynaklar Bakanlığı", <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>, Son Erişim Tarihi:12.11.2023
- ETKB 3.(2023). "Enerji ve Tabii Kaynaklar Bakanlığı", https://enerji.gov.tr/Media/Dizin/EIGM/tr/Raporlar/TUEP/T%C3%BCrkiye_Ulusal_Enerji_Plan%C4%B1.pdf, Son Erişim Tarihi:13.11.2023
- ETKB 4.(2023). "Enerji ve Tabii Kaynaklar Bakanlığı", <https://enerji.gov.tr/duyuru-detay?id=20405>, Son Erişim Tarihi:18.11.2023
- JKBB.(2023). "T.C. Enerji Kentleri Birliği", <http://www.jkbb.org.tr/Icerik-213-YenilenebilirEnerji>, Son Erişim Tarihi:17.11.2023
- Gao, Q., Liu, Y., Yang, J. and Hong, Y. (2021). "Comparative Research on Electricity Consumption Forecast Based on Deep Learning", *In 2021 2nd International Conference on Artificial Intelligence and Education (ICAIE)*, 213-217.

- Gao, Y., Liu, W. and Lombardi, F. (2020). “Design and Implementation of an Approximate Softmax Layer for Deep Neural Networks In 2020”, **IEEE International Symposium on Circuits and Systems (ISCAS)**, (pp. 1-5). IEEE.
- Gezer, M. ve Saylan, S. (2017), “Açık Kaynaklı Makine Öğrenmesi Kütüphaneleri”, Mühendislikte Yapay Zeka ve Uygulamaları, **“Sakarya Üniversitesi Kütüphanesi Yayınevi”**, Sakarya, (53-64).
- Gezmez, K. Ç. (2022). “Bir İlin Elektrik Tüketim Verilerinin Makine Öğrenmesi Yöntemleri ile Analizi”, Yüksek Lisans Tezi, **Başkent Üniversitesi Fen Bilimler Enstitüsü**, Ankara.
- Golovinski, P., Vasenin, D., Savvin, N., Rinaldi, S. and Pasetti, M. (2022). “Electricity Consumption Forecast of Clusters of Buildings Based on Recurrent Neural Networks”, **In 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)**, 375-380.
- Görgülü, Y. F. (2022). “Enerji Krizi ve Yenilenemez Enerji Kaynakları”, **Teknobilim-2022: Enerji Krizi ve Yenilenebilir Enerji**, 7.
- Gültepe, Y. (2019). “Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme”, **Avrupa Bilim ve Teknoloji Dergisi**, (16), 8-15.
- Gür, Y. E., Ayden, C. ve Yücel, A. (2019). “Yapay Zekâ Alanındaki Gelişmelerin İnsan Kaynakları Yönetimine Etkisi”, **Fırat Üniversitesi Uluslararası İktisadi ve İdari Bilimler Dergisi**, 3(2), 137-158.
- Güven, H. ve Güven, E. T. A. (2023). “Yapay Zekâ Uygulamalarının E-Ticarette Kullanımı.”, **International Journal of Management and Administration**, 7(13), 69-94.
- Haliloğlu, E. Y. ve Tutu, B. E. (2018). “Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini”, **Yaşar Üniversitesi E-Dergisi**, 13(51), 243-255.
- Hamzaçebi, C. ve Kutay, F. (2004). “Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 19(3).
- Han, G., Sönmez, E. F., Avcı, S. ve Aladağ, Z. (2022). “Uygun Normalizasyon Tekniği ve Yapay Sinir Ağları Analizi ile Otomobil Satış Tahminlemesi”, **İşletme Ekonomi ve Yönetim Araştırmaları Dergisi**, 5(1), 19-45.
- Hasanova, N. (2021). “Akıllı Binalarda Talep Tarafı Enerji Yönetimi”, Yüksek Lisans Tezi, **Marmara Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı**, İstanbul

- Hoşgör, H. ve Güngördü, H. (2022). “Sağlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Araştırma”, *Avrupa Bilim ve Teknoloji Dergisi*, (35), 395-407.
- Hussain, A., Rahman, M. and Memon, J. A. (2016). “Forecasting Electricity Consumption in Pakistan: The Way Forward”, *Energy Policy*, 90, 73-80.
- IEA.(2019). ”World Energy Outlook 2019”,*International Energy Agency*,Paris, France: IEA.
- IEA. (2023). “World Energy Outlook 2023”, *International Energy Agency*,Paris, France: IEA.
- İnce, İ. F. Bölüm 6 (2021). “Bilişim Projelerinde Sınıflandırma Algoritmalarıyla Yönetimsel Risk Tespiti”, İşletme Biliminden Seçkin Araştırmalar, *Duvar Yayınları*, 102-119
- İrdem, İ.,& Çobanoğlu, S. (2021). “Yapay Zekanın İç Güvenlik Yönetimi Üzerine Yansımaları: Siber Güvenlik”, *Kamu Yönetimi ve Teknoloji Dergisi*, 3(2), 175-202.
- İsmiç, B. (2015).” Gelişmekte Olan Ülkelerde Elektrik Tüketimi, Ekonomik Büyüme ve Nüfus İlişkisi”, *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 5(1), 259-274.
- Jayalakshmi, T. and Santhakumaran, A. (2011). “Statistical Normalization and Back Propagation for Classification”, *International Journal of Computer Theory and Engineering*, 3(1), 1793-8201.
- Kabalcı, E. (2014). “Yapay Sinir Ağları”,
<https://ekblc.files.wordpress.com/2013/09/ysa.pdf>,
Erişim Tarihi: 17.11.2023.
- Kamber, E.,Körpüz, S., Can, M., Aydoğmuş, H. Y. ve Gümüş, M. (2021). “Yapay Sinir Ağlarına Dayalı Kısa Dönemli Elektrik Yüğü Tahmini”, *Endüstri Mühendisliği*, 32(2), 364-379.
- Kamber, E., Körpüz, S., Can, M., Aydoğmuş, H. Y. ve Gümüş, M. (2021). “Yapay Sinir Ağlarına Dayalı Kısa dönemli Elektrik Yüğü Tahmini”, *Endüstri Mühendisliği*, 32(2), 364-379.
- Kar, M., Ağır, H. ve Türkmen, S. (2018). “Gelişmekte Olan Ülkelerde Elektrik Tüketimi ile Ekonomik Büyüme İlişkisinin Ekonometrik Tahmini”, *ICPESS 2018 PROCEEDINGS Volume 2: Economic Studies*, 305.
- Karabulut, Y. (2004). “Türkiye’de Elektrik Enerjisi Üretimi”, *Ankara Üniversitesi Türkiye Coğrafyası Araştırma ve Uygulama Merkezi Dergisi*, 3, 53-77.

- Karaca, C. ve Karacan, H. (2016). “Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi”, *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 4(3), 182-195.
- Karabay, B. ve Ulaş, M. (2017). “Büyük Veri İşlemede Yaygın Kullanılan Araçların Karşılaştırılması”, *In 8th International Advanced Technologies Symposium*, 1-18
- Karagöl, E., Erbaykal, E. ve Ertuğrul, H. M. (2007). “Türkiye’de Ekonomik Büyüme ile Elektrik Tüketimi İlişkisi: Sınır Testi Yaklaşımı”, *Doğuş Üniversitesi Dergisi*, 8(1), 72-80.
- Karaman, Ö. A. ve Bektaş, Y. (2023). “Makine Öğrenmesi ve Optimizasyon Yöntemleri ile Uzun Dönem Elektrik Enerjisi Tahmini: Türkiye Örneği”, *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 285-292.
- Karatay, S. ve Algahani, M. (2021). “1999 Marmara Depremi ve Güneş Tutulmasının Naive Bayes Sınıflayıcısı ile İstatistiksel Analizi”, *Avrupa Bilim ve Teknoloji Dergisi*, (23), 643-648
- Kaya, Y. (2010). “Türk Telekomünikasyon AŞ’de Elektrik Enerjisi Tüketiminin Yapay Sinir Ağları ile Yerel Tahmini”, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). “Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi”, *Harita Dergisi*, 144(7), 73-82.
- Kaynar, O., Yüksek, A. G. ve Demirkoparan, F. (2016). “Genetik Algoritma ile Eğitilmiş Destek Vektör Regresyon Kullanılarak Türkiye’nin Elektrik Tüketim Tahmini”, *Journal of the Faculty of Economics / İktisat Fakültesi Mecmuası*, 66(2).
- Kaytez, F.(2012). “En Küçük Kareler Destek Vektör Makineleri ile Türkiye’nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellemesi”, *Doktora Tezi*, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- .Keleş, M. B., Keleş, A. ve Keleş, A. (2020). “Makine Öğrenmesi Yöntemleri ile Uçuş Fiyatlarının Tahmini”, *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 7(11), 72-78.
- Keramati, H. and Hamdullahpur, F. (2022). “Deep Convolutional Surrogate Sanddegrees of Freedom in the Rmaldesign”, <https://arxiv.org/abs/2208.07482>, Erişim Tarihi: 18.11.2023.
- Keskenler, M. F. ve Keskenler, E. F. (2017). “Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi”, *Takvim-i Vekayi*, 5(2), 8-18.

- Keskin, M. V. ve Yıldız, D. (2018). “Büyük Veri Araçları ve R Kullanarak Amerikan Havaolu Firmalarının Sorunlarının Keşfedilmesi”, *Uygulamalı Sosyal Bilimler Dergisi*, 2(2), 1-19.
- Kılıç, S. (2013). “Doğrusal Regresyon Analizi.”, *Journal of Mood Disorders*, 3(2), 90-92.
- Kılınç, D., Borandağ, E., Yücalar, F., Tunali, V., Şimşek, M. ve Özçift, A. (2016). “KNN Algoritması ve R Dili ile Metin Madenciliği Kullanılarak Bilimsel Makale Tasnifi”, *Marmara Fen Bilimleri Dergisi*, 28(3), 89-94.
- Kılınç, G., Karaatlı, M. ve Ömürbek, N. (2022). “Türkiye Limanlarındaki Konteyner ve Yük Elleçleme Hacimlerinin YSA Narx Modeli ile Öngörülmesi”, *Verimlilik Dergisi*, (2), 251-266.
- Kıvrak, E. A., Karasulu, B., Sözbir, C. ve Türkay, A. (2021). “Ses Özneteliklerini Kullanan Ses Duygu Durum Sınıflandırma İçin Derin Öğrenme Tabanlı Bir Yazılımsal Araç”, *Veri Bilimi*, 4(3), 14-27.
- Kocadayı, Y., ErKaymaz, O. ve Uzun, R. (2017). “Yapay Sinir Ağları ile Tr81 Bölgesi Yıllık Elektrik Enerjisi Tüketiminin Tahmini.”, *International Journal of Science and Technology Research*, 1(1), 59-64.
- Koç, A., Yağlı, H., Koç, Y. ve Uğurlu, İ. (2018). “Dünyada ve Türkiye’de Enerji Görünümünün Genel Değerlendirilmesi”, *Mühendis ve Makina*, 59(692), 86-114.
- Koç, E. ve Kadir, K. (2015). “Enerji Kaynakları – Yenilenebilir Enerji Durumu”, *Mühendis ve Makina*, 56(668), 36-47.
- Korkut, U. B., Göktürk, Ö. B. and Yıldız, O. (2018). “Detection of Plant Diseases by Machine Learning. In 2018”, *26th Signal Processing and Communication Sapplication Sconference (SIU)*, (pp. 1-4), IEEE.
- Köroğlu, Y. (2017). “Yapay Zeka’nın Teorik ve Pratik Sınırları.”, *Boğaziçi Üniversitesi Yayinevi*, 26-30.
- Kramer, O. and Kramer, O. (2013). “K-nearest Neighbors Dimensionality Reduction With Unsupervised Nearest Neighbors”, *Springer Berlin Heidelberg*, 13-23.
- Kumar, V. (2012). “101 Designmethods: A Structure Dapproach for Driving Innovation in Your Organization”, *John Wiley&Sons*, Canada.
- LaValley, M. P. (2008). “Logistic Regression”, *Circulation*, 117(18), 2395-2399.
- Malkoç, B. (2012). “Temel Bilimler ve Mühendislik Eğitiminde Programlama Dili Olarak Python”, *XIV. Akademik Bilişim Konferansı Bildirileri*, 201.

- Maltarollo, V. G., Honório, K. M. and Da Silva, A. B. F. (2013). "Applications of Artificial Neural Networks in Chemical Problems", **Artificial Neural Networks Intech**, London.
- Makas, Y. ve Karaatlı, M. (2016). "Yapay Sinir Ağlarıyla Hidroelektrik Enerji Tüketiminin Çok Dönemli Tahmini", **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 21(3), 757-772.
- Marvuglia, A. and Messineo, A. (2012). "Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption", **Energy Procedia**, 14, 45-55.
- Masaebi, P. (2016). "Yapay Sinir Sğları ile İran Elektrik Tüketim Tahmini ", Yüksek Lisans Tezi, **Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü**, Trabzon
- Meral, G. ve Saraçlı, S. (2020). "Destek Vektör Makineleri ve Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama", **Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 24(2), 411-418.
- Meral, M. E., Ahmet, T. ve Tümay, M. (2009). "Elektrik Tesislerinde Enerji Verimliliği", **Uludağ Üniversitesi Mühendislik Fakültesi Dergisi**, 14(1).
- Metin, H. (2018). "Yapay Sinir Ağları Yöntemiyle Türkiye'de Elektrik Enerjisi Tüketimi Tahmini", Yüksek Lisans Tezi, **İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul.
- Miracozturk.(2023)."Python İle Sınıflandırma Analizleri",
<https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi/>,
Son Erişim Tarihi :13.11.2023
- Moazzen, N., Karagüler, M. E., Ashrafian, T. ve Aktürk, Ö. (2019), "Bir İlköğretim Binasının Yaşam Döngüsü Enerji Verimliliği Değerlendirilmesi", **14. Ulusal Tesisat Mühendisliği Kongresi**, İzmir
- Mohamed, Z. and Bodger, P. (2005). "Forecasting Electricity Consumption in New Zealand Using Economic and Demographic Variables", **Energy**, 30(10), 1833-1843.
- Muhsin, K. ve Kınık, E. (2008)." Türkiye'de Elektrik Tüketim Çeşitleri ve Ekonomik Büyüme Arasındaki İlişkinin Ekonometrik Bir Analizi", **Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 10(2), 333-353.
- Murphy, K. P. (2012). "Machine Learning: A Probabilistic Perspective", **The MIT Press**, London.
- Nebati, E. E., Taş, M. ve Ertaş, G. (2021). "Türkiye'de Elektrik Tüketiminde Talep Tahmini: Zaman Serisi Ve Regresyon Analizi İle Karşılaştırma ", **Avrupa Bilim ve Teknoloji Dergisi**, (31), 348-357.

- Nick, T. G. and Campbell, K. M. (2007). “Logistic Regression”, *Topics in Biostatistics*, 273-301.
- Nişancı, M. (2005). “Türkiye’de Elektrik Enerjisi Talebi ve Elektrik Tüketimi ile Ekonomik Büyüme Arasındaki İlişki”, *Sosyal Ekonomik Araştırmalar Dergisi*, 5(9), 107-121.
- Nokour, M. A. ve Gülbandılar, E. (2023). “Derin Öğrenme Metotlarını Kullanarak Arapça Metin Tabanlı Duygu Analizi”, *Mühendislikte Yenilikçi Çalışmalar*, 217-245.
- Odası, M. M. (2008). “Dünyada ve Türkiye’de Enerji Verimliliği Oda Raporu”, *TMMOB Makine Mühendisleri Odası*, Ankara.
- Of, M. ve Kılıçaslan, İ. (2021). “Kolay Bir Programlama Dili Olan Python ile Nesneye Dayalı Programlama”, *Premium e-Journal of Social Science (PEJOSS)*, 5(17), 720-727.
- Oğuzlar, A. (2005). “Lojistik Regresyon Analizi Yardımıyla Suçlu Profiline Belirlenmesi”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 19(1), 21-35.
- Onan, A. ve Korukoğlu, S. (2016). “Makine Öğrenmesi Yöntemlerinin Görüş Madenciliğinde Kullanılması Üzerine Bir Literatür Araştırması”, *Pamukkale University Journal of Engineering Sciences*, 22(2).
- Öksüz, S. (2019). “Yapay Sinir Ağları ile Denizli İli Mesken Aboneleri Elektrik Tüketim Tahmini”, Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen bilimleri Enstitüsü*, Denizli.
- Özalp, M. (2019). “Küresel Ölçekte Türkiye’nin Enerji Arz ve Talep Güvenliği”, *Electronic Turkish Studies*, 14(1).
- Özbakır, P. (2006). “Enerji yönetimi”, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Özçağlayan, M. ve Yeniceler Kortak, İ. (2023). “Medya Takip Merkezleri Üzerinden Türkiye’de Yapay Zekânın Medyadaki Kullanımının Değerlendirilmesi”, *The Turkish Online Journal of Design Art and Communication*, 13 (3), 700-714.
- Özdemir, D. (2011). “Yapay Sinir Ağları ile Kocaeli İlinin Puant Yük Tahmini “, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, Kocaeli.
- Özdemir, M. E. (2021). “Yapay Sinir Ağları Kullanılarak Orta Dönem Elektrik Enerjisi Tüketim Tahmini: İskenderun Örneği”, *Avrupa Bilim ve Teknoloji Dergisi*, (28), 489-492.
- Özden, S. ve Öztürk, A. (2018). “Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (OSB) Elektrik Enerjisi İhtiyaç Tahmini”, *Bilişim Teknolojileri Dergisi*, 11(3), 255-261.

- Özen, N. S., Saraç, S. ve Koyuncu, M. (2021). "COVID-19 Vakalarının Makine Öğrenmesi Algoritmaları ile Tahmini: Amerika Birleşik Devletleri Örneği", *Avrupa Bilim ve Teknoloji Dergisi*, (22), 134-139.
- Özgül, F. (2006). "PYTHON: Kaynağından, En Güncel Teknikler", *KODLAB Yayın Dağıtım*, İstanbul.
- Özgül, V. U. P. A. ve Alma, Ö. G. (2008). "Regresyon Analizinde Kullanılan En Küçük Kareler ve En Küçük Medyan Kareler Yöntemlerinin Karşılaştırılması", *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 3(2), 219-229.
- Özkan, E., Güler, E. ve Aladağ, Z. (2020). "Elektrik Enerjisi Tüketim Verileri İçin Uygun Tahmin Yöntemi Seçimi", *Endüstri Mühendisliği*, 31(2), 198-214.
- Öztemel, E. (2003). "Yapay Sinir Ağları", *Papatya Yayıncılık*, İstanbul.
- Öztürk, K. ve Şahin, M. E. (2018). "Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış", *Takvim-i Vekayi*, 6(2), 25-36.
- Pavlicko, M., Vojteková, M. and Blažeková, O. (2022). "Forecasting of Electrical Energy Consumption in Slovakia", *Mathematics*, 10(4), 577.
- Pekmezci, A. (2020). "Kişi Başına Elektrik Tüketiminin Dalgacık Dönüşümüne Dayalı Tahmini", *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 24(3), 702-706.
- Pençe, İ., Kalkan, A. ve Çeşmeli, M. Ş. (2019). "Türkiye Sanayi Elektrik Enerjisi Tüketiminin 2017-2023 Dönemi İçin Yapay Sinir Ağları ile Tahmini", *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 3(2), 206-228.
- Peterson, L. E. (2009). "K-nearest Neighbor", *Scholarpedia*, 4(2), 1883.
- Pirim, A. G. H. (2006). "Yapay Zeka", *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Polatgil, M. (2023). "Veri Ölçekleme ve Eksik Veri Tamamlama Yöntemlerinin Makine Öğrenmesi Yöntemlerinin Başarısına Etkisinin İncelenmesi", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(1), 78-88.
- Priyadarshana, A., Lokupitiya, R. S., Kuruppuarachchi, D. and Lokupitiya, E. Y. K. (2021). "Using Weather Patterns to Forecast Electricity Consumption in Sri Lanka: An ARDL Approach", *International Energy Journal* 21, 257-268.
- Putra, A. D. A. and Juanita, S. (2021). "Analisis Sentimen Pada Ulasan Pengguna Aplikasi Bibit Dan Bareksadengan Algoritma KNN", *JATISI (Jurnal Teknik Informatikadan Sistem Informasi)*, 8(2), 636-646.

- Ramos, D., Faria, P., Vale, Z. and Correia, R. (2021). "Short Time Electricity Consumption Forecast in an Industry Facility", *IEEE Transactions on Industry Applications*, 58(1), 123-130.
- Russell, S. J. and Norvig, P. (2010). "Artificial Intelligence a Modern Approach", *Prentice Hall*, London.
- Saranya, C. and Manikandan, G. (2013). "A Study on Normalization Techniques for Privacy Preserving Data Mining", *International Journal of Engineering and Technology (IJET)*, 5(3), 2701-2704.
- Sayar, A. ve Ergün, U. (2014). "Fonksiyonel Programlama Dilleri ile Paralel Programlama", *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 3(2), 1-17.
- Sezgin, E. ve Çelik, Y. (2013). "Veri Madenciliğinde Kayıp Veriler İçin Kullanılan Yöntemlerin Karşılaştırılması", *Akademik Bilişim Konferansı*, Akdeniz Üniversitesi, 23-25.
- Shibano, K. and Mogi, G. (2020). "Electricity Consumption Forecast Model Using Household Income: Case Study in Tanzania", *Energies*, 13(10), 2497.
- Sigeze, Ç. (2021). "Türkiye’de Hanehalkı Elektrik Talebinin İki Aşamalı Model ile İncelenmesi", *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(2), 531-552.
- Soegoto, E. S., Utami, R. D. and Hermawan, Y. A. (2019). "Influence of Artificial Intelligence in Automotive Industry", *In Journal of Physics: Conference Series*, Vol. 1402, No. 6, p. 066081.
- Solmaz, R., Günay, M. ve Alkan, A. (2014). "Fonksiyonel Tiroit Hastalığı Tanısında Naive Bayes Sınıflandırıcının Kullanılması", *Akademik Bilişim Konferansı*, Mersin, 891-897.
- Şahin, Y. (2020). "Gelecek Dönemlere Ait Türkiye Elektrik Tüketimi Tahmininde Yapay Sinir Ağları Modelinin Kullanılması", Yüksek Lisans Tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul.
- Şahinaslan, Ö., Dalyan, H. ve Şahinaslan, E. (2022). "Naive Bayes Sınıflandırıcısı Kullanılarak Youtube Verileri Üzerinden Çok Dilli Duygu Analizi", *Bilişim Teknolojileri Dergisi*, 15(2), 221-229.
- Şahinler, S. (2000). "En Küçük Kareler Yöntemi ile Doğrusal Regresyon Modeli Oluşturmanın Temel Prensipleri", *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 5(1-2), 57-73.
- Şapcı, B. (2022). "Mimarlıkta Makine Öğrenimi Uygulamaları: Fırsatlar, Zorluklar ve Geleceğe Dair Öngörüler", Yüksek Lisans Tezi, *Başkent Üniversitesi Fen Bilimler Enstitüsü*, Ankara.

- Şen, Z. (2004). “Yapay Sinir Ağları”, **Su Vakfı**, İstanbul.
- Şengöz, M. (2021). “Ulusal Enerji Yönetimi.”, **Uluslararası Politik Araştırmalar Dergisi**, 7(1), 73-85.
- TEDAŞ.(2023).”2021 Yılı Türkiye Elektrik Dağıtım Sektör Raporu”,
https://www.tedas.gov.tr/fileupload/mediafolder/sx.web.docs/tedas/docs/Stratejikplan/2021_Yili_Turkiye_Elektrik_Dagitimi_Sektor_Raporu.pdf,
Son Erişim Tarihi:10.11.2023
- Tanrikulu, H. ve Sazlı, M. H. (2009). “Saldırı Tespit Sistemlerinde Yapay Sinir Ağlarının Kullanılması”, Yüksek Lisans Tezi, **Ankara Üniversitesi Fen Bilimleri Enstitüsü**, Ankara.
- Taşcı, E. ve Onan, A. (2016). “K-en Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi”, **Akademik Bilişim**, 1(1), 4-18.
- Tekin, T. G. ve Patır, S. (2023). “ Amerikan Dolar Kurunun Yapay Sinir Ağları Yöntemiyle Tahminlenmesi: 2009–2021 Dönemi”, **R&S-Research Studies Anatolia Journal**, 6(1), 56-77.
- Thota, L. S. and Chandalasetty, S. B. (2013). “Optimum Learning Rate For Classification Problem With MLP in Data Mining”, **International Journal of Advances in Engineering & Technology**, 6(1), 35.
- Toker, A. C. ve Korkmaz, O. (2010). “Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi”, **In Proceedings** ,Vol 17, 32-35.
- Töman, U. ve Çimer, S. O. (2011). “Enerji Kavramının Farklı Öğrenim Seviyelerinde Öğrenilme Durumunun Araştırılması”, **Bayburt Eğitim Fakültesi Dergisi**, 6(1), 31-43.
- Tunç, A. ve Ülger, İ. (2016). “Veri Madenciliği Uygulamalarında Özellik Seçimi İçin Finansal Değerlere Binning ve Five Number Summary Metotları ile Normalizasyon İşleminin Uygulanması”, **XVIII. Akademik Bilişim Konferansı**, Adnan Menderes Üniversitesi, 30, 3.
- Tungut, H. B. (2021). “Algoritma ve Programlama Mantığı”, **Kodlap Yayın Dağıtım Yazılım LTD. ŞTİ.**,Vol. 108
- Tuzcu, S. (2020). “Çevrimiçi Kullanıcı Yorumlarının Duygu Analizi ile Sınıflandırılması”, **Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi**, 1(2), 1-5.

- Tütün, S.(2012). “Yapay Zekâ Teknikleri ile Elektrik Enerjisi Net Tüketim Tahmini: Türkiye Örneği”, Yüksek Lisans Tezi, **Erciyes Üniversitesi Fen Bilimleri Enstitüsü**, Kayseri.
- Uçak, K. (2012). “Destek Vektör Regresyonu İle Pıd Kontrolör Tasarımı “, Yüksek Lisans Tezi, **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul.
- Usta, S. (2022). “Karadeniz Bölgesi İklim Koşullarına Uygun Jensen Haise Yöntemi Referans Evapotranspirasyon Tahmin Eşitliklerinin Geliştirilmesi”, **Avrupa Bilim ve Teknoloji Dergisi**, (38), 415-427.
- Uzlu, E. ve Dede, T. (2020). “Jaya Algoritması ile Optimize Edilmiş Yapay Sinir Ağlarını Kullanarak Türkiye’de Elektrik Enerjisi Tüketiminin Tahmini”, **Gazi University Journal of Science Part C: Design and Technology**, 8(3), 511-528.
- Uzun, E. (2019). “Farklı Yöntemler Kullanılarak Bursa ve Türkiye İçin Elektrik Enerjisi Talep Tahmini”, Yüksek Lisans Tezi, **Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü**, Bursa.
- Ülkü, H. ve Yalpir, Ş. (2021). “Enerji Talep Tahmini İçin Metodoloji Geliştirme: 2030 yılı Türkiye örneği”, **Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, 10(1), 188-201.
- Üremiş, İ.,Yörü, Y., Erkul, B., Bağcı, N., Canpek, C. ve Çırak, G. (2013), “Gelecek Nesilleri Kazanmak İçin Enerji Yönetimli Okullar Projesi”, **Sunuş Yazıları**, 61.
- Velasquez, C. E., Zocatelli, M., Estanislau, F. B. and Castro, V. F. (2022). “Analysis of Time Series Models for Brazilian Electricity Demand Forecasting”, **Energy**, 247, 123483.
- Vergili, M. ve Orhan, H. (2022). “Genomik Veri Setlerinin LASSO ve Elastik Net Regresyon Yöntemleri ile Analizi”, **Süleyman Demirel Üniversitesi Sağlık Bilimleri Dergisi**, 13(3), 485-496.
- Wikipedia.(2023). “Dünya Enerji Tüketimi”,
https://tr.wikipedia.org/wiki/D%C3%BCnya_enerji_t%C3%BCketimi,
Son Erişim Tarihi: 09.11.2023
- Yalçınöz, T., Herdem, S. ve Eminoğlu, U. (2002). “Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini”, **Niğde Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü**, Niğde.
- Yao, W. and Li, L. (2014). “A New Regression Model: Modal Linear Regression”, **Scandinavian Journal of Statistics**, 41(3), 656-671.
- Yavuzdemir, M. Y. ve Gökğöz, F. T. D. (2014). “Türkiye’nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini”, Doktora Tezi, **Ankara Üniversitesi Sosyal Bilimler Enstitüsü**, Ankara

- Yayla, G. A. (2019). “Matlab”, **Kodlab Yayın Dağıtım Yazılım ve Eğitim Hizmetleri San. Ve Tic. Ltd. Şti.**, İstanbul.
- Yılankıran, N. ve Doğan, H. (2020). “Türkiye’nin Enerji Görünümü ve 2023 Yılı Birincil Enerji Arz Projeksiyonu”, **Batman Üniversitesi Yaşam Bilimleri Dergisi**, 10(2), 77-92.
- Yıldırım, G. (2010). “Malatya İl Milli Eğitim Müdürlüğüne Ait Okulların Elektrik, Su ve Doğalgaz Faturalarının İncelenmesi”, Yüksek Lisans Tezi, **Beykent Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul.
- Yıldırım, M. (2021). “Bazı Veri Madenciliği Yöntemleri ile Elektrik Tüketim Tahmini “, Yüksek Lisans Tezi, **Harran Üniversitesi Fen Bilimleri Enstitüsü**, Şanlıurfa.
- Yıldız, A. (2022). “Finans Alanında Yapay Zeka Teknolojisinin Kullanımı: Sistemik Literatür İncelemesi”, **Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, (52), 47-66.
- Yıldız, E. (2021). “Güç Sistemlerinde Kayıplar ve Kaçakların Birbirinden Ayrılması İçin Önerilen Tahmin Algoritması”, Yüksek Lisans Tezi, **Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü**, Konya.
- Yılmaz, V. (2010). “Enerji Talebi ve Tokat’ta Elektrik Enerjisi Talebi Üzerine Bir Uygulama”, Yüksek Lisans Tezi, **Gaziosmanpaşa Üniversitesi Sosyal Bilimleri Enstitüsü**, Tokat.
- Yılmazel, Ö., Afşar, A. ve Yılmazel, S. (2018). “Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması”, **UIİİD-IJEAS**, 2018 (20):285-300 ISSN 1307-9832
- Yılmazel, Ç. (2019).” Üroflovetre-elektromiyografi Sinyalleri Sınıflandırılarak Alt Üriner Sistem Disfonksiyonu İçin Tıbbi Karar Destek Sistemi Oluşturulması”, Yüksek Lisans Tezi, **TOBB University of Economics and Technology, Graduate School of Engineering and Science**, Ankara.
- Yurtsever, U. (2002). “Veri Madenciliği ve Uygulaması”, Yüksek Lisans Tezi, **Sakarya Üniversitesi Sosyal Bilimler Enstitüsü**, Sakarya.
- Yusuf, A. ve Soner, T. A. K. (2003). “Türkiye Elektrik Enerjisi Ekonometrik Talep Analizi”, **Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 17(1-2).
- Yüce H. ve Özkan, A. O. (2021).“Normalizasyon Yöntemlerinin Biyomedikal Verilerde Sınıflandırma Performansına Etkisi”, **Avrupa Bilim ve Teknoloji Dergisi**, (30), 35-43.
- Yükçü, S. ve İçerli, M. Y. (2023). “Güneş Enerjisi Vak’a Analizi”, **İşletme Akademisi Dergisi**, 4(3), 284-290.

- Zolfaghari, M. and Sahabi, B. (2019). "A Hybrid Approach to Model and Forecast The Electricity Consumption by Neuro Wavelet and ARIMAX-GARCH Models", *Energy Efficiency*, 12, 2099-2122.
- Zou, B. and Sun, J. (2022). "Mid-term Forecast of Electricity Consumption of Enterprises Based on Bi-Directional LSTM and Nonpooling CNN", *In 2022 IEEE 2nd International Conference on Data Science and Computer Application (ICDSCA)*, 1236-1240.

